

Aapi von Creutlein

Opas attribuutiomallinnuksen toteuttamiseen Google Analyticsilla

Metropolia Ammattikorkeakoulu

Tradenomi

Liiketalous

Opinnäytetyö

8.2.2016

Tekijä	Aapi von Creutlein
Otsikko	Opas attribuutiomallinnuksen toteuttamiseen Google Analyticsilla
Sivumäärä Aika	20 sivua + 1 liite 8.2.2016
Tutkinto	Tradenomi
Koulutusohjelma	Liiketalous
Suuntautumisvaihtoehto	Markkinointi
Ohjaajat	Lehtori Raisa Varsta Head of Research Kirsi Laine
<p>Median pirstaloituminen on saanut mainostajat pohtimaan, kuinka mainosbudjetti tulisi jakaa kustannustehokkaimmin eri digitaalisten kanavien välillä. Attribuutiomallinnus on web-analytiikan osa-alue, jonka avulla pyritään selvittämään kunkin kanavan merkitys liiketoiminnallisen tavoitteen kannalta. Tämän opinnäytetyön aiheena oli tutkia attribuutiomallinnuksen toimintaa ja luoda yksinkertainen ohjeistus sen käyttöönottoa varten.</p> <p>Opinnäytetyö on muodoltaan toiminnallinen opinnäytetyö, ja se koostuu kahdesta osasta. Ensimmäisessä osassa käsitellään keskeinen ammattisanasto, määritellään attribuutiomallinnuksen rooli muiden mainonnan mittauskeinojen joukossa ja käydään läpi mallinnuksen perusidea sekä digitaalisen mainonnan mittaamisen suurimmat haasteet. Toinen osa on varsinainen tuotos, attribuutiomallinnusprosessin työvaiheet esittelevä opas.</p> <p>Opinnäytetyön johtopäätöksenä todettiin, että attribuutiomallinnusta tulisi käyttää mediaostamisen tukena, mutta sen ei tulisi olla ainoa päätöksentekoon vaikuttava tekijä. Erityisen paljon mallinnuksesta saadaan hyötyä, jos suurin osa mainospanostuksista sijoittuu internetiin, mallinnusta työtetään systemaattisesti jatkuvana prosessina, ja sen tuottaman tiedon tueksi otetaan käyttöön myös muita tutkimusmenetelmiä.</p>	
Avainsanat	Attribuutiomallinnus, web-analytiikka, Google Analytics, mediasuunnittelu

Author Title	Aapi von Creutlein Guidebook on attribution modeling with Google Analytics
Number of Pages Date	20 pages + 1 appendice 8 February 2016
Degree	Bachelor of Business Administration
Degree Programme	Business Administration
Specialisation option	Marketing
Instructors	Raisa Varsta, Senior Lecturer Kirsi Laine, Head of Research
<p>The fragmentation of the media landscape has raised a question among marketers about how to allocate the media budget most cost-efficiently between the digital channels. A part of web analytics, attribution modeling, is a method that helps to find out the value of each advertising channel in terms of the business objectives. The purpose of this thesis was to study the function of attribution modeling, and produce simple instructions for its implementation.</p> <p>This is a functional study that consists of two parts. The first part discusses the key terminology, the role of attribution modeling among other measurement methods, the basic idea of attribution modeling and the current challenges of measuring digital advertising. The second part is the actual result, a guidebook that introduces the general steps of implementing attribution modeling.</p> <p>The conclusion of this thesis was that attribution modeling should be used as a supportive mean in media buying, but it should not be the only guiding factor in the decision-making. Furthermore, attribution modeling is most beneficial when most of the media budget is used online, the process of attribution modeling is continuous, and other research methods are used to complement the data it provides.</p>	
Keywords	Attribution modeling, web analytics, Google Analytics, media planning

Sisällys

1	Johdanto	1
1.1	Työn aihe ja tavoite	1
1.2	Rajaukset	2
1.3	Keskeiset käsitteet ja lyhenteet	2
2	Digitaalisen mainonnan mittaus	5
2.1	Digitaalisen mainonnan mittauksen keinot	5
2.2	Digitaalisen attribuutiomallinnuksen määritelmä ja käyttötarkoitus	6
2.2.1	Attribuutiomallinnuksen rooli mediasuunnittelussa	7
2.2.2	Konversio	8
2.2.3	Käytettävyys ja A/B-testaus	9
2.3	Verkkomainonnan mittaamisen haasteet	10
2.3.1	Ihmiset, selaimet ja evästeet	11
2.3.2	Mainostenesto-ohjelmat, todennetut mainosnäytöt ja botit	11
2.3.3	Attribuutiomallinnuksen haasteet	13
3	Yhteenveto	15
3.1	Johtopäätökset ja suositukset	15
3.2	Jatkotutkimusaiheet	16
3.3	Kirjoitusprosessi	17
3.4	Arvio työstä	18
	Lähteet	19

Liitteet

Liite 1. Opas attribuutiomallinnuksen toteuttamiseen Google Analyticsilla

1 Johdanto

1.1 Työn aihe ja tavoite

Opinnäytetyöni käsittelee attribuutiomallinnusta, eli keinoa digitaalisen mainonnan vaikuttavuuden ja tuottavuuden mittaamiseksi. Työn tarkoituksena on tuottaa ohjeistus attribuutiomallinnuksen aloittamista varten, ja samalla oppia sen perusteet ja tekninen toiminta. Aiheesta ei ole aiemmin kirjoitettu opinnäytetyötä Suomessa.

Mediapanostusten tuloksellisuuden mittaaminen on tärkeää, koska mitä enemmän mainosbudjetti kasvaa, sitä tärkeämpää on tietää mitkä kanavat ovat kaikkein tuloksellisimpia liiketoiminnan tavoitteiden kannalta. Attribuutiomallinnuksella saadaan selville, mitkä eri mainonnan osat toimivat parhaiten missäkin osassa ostoprosessia. (Salo 2015.)

Tämä opinnäytetyö on toiminnallinen opinnäytetyö, jonka tuotos on opas attribuutiomallinnuksen suunnitteluun ja toteuttamiseen Google Analytics -työkalulla. Työ on suunnattu digitaalisen mainonnan ja -median parissa työskenteleville henkilöille, jotka haluavat perehtyä tähän web-analytiikan osa-alueeseen. Tuotosta tullaan käyttämään kirjoitushetken työnantajani sisäisenä koulutusmateriaalina.

Työ on kaksiosainen. Tässä raporttiosassa kerron teoriaa työn aiheesta sekä kuvailen työn syntyprosessin ja lopputulokset. Toinen osa (liite 1) on varsinainen tuotos, jossa kuvaan attribuutiomallinnuksen toteutuksen Google Analyticsin avulla.

Tavoitteenani on, että työn lukija oppii mitä attribuutiomallinnus on, perusteet sen käytölle ja haasteet, teknisen toiminnan, ja hahmottaa oikein toteutetun attribuutiomallinnuksen rahallisen hyödyn liiketoiminnassa sekä roolin mediasuunnittelun päätöksenteossa. Tavoitteena on myös, että lukija pystyy työn avulla arvioimaan attribuutiomallinnuksen tarvetta omalle tai asiakasyrityksensä liiketoiminnalle.

Jos web-analytiikan ja tiedolla johtamisen perusteet, käyttötarkoitus ja hyödyt eivät ole entuudestaan tuttuja, suosittelen ennen tämän työn lukemista lukemaan esimerkiksi Thomas H. Davenportin ja Jeanne G. Harrisin kirjan *Analysoi ja voita: kilpailun uusi tiede* (2007).

Google Analyticsin historiaa, toimintaperiaatetta ja hyötyjä esitellään esimerkiksi vuonna 2015 julkaistussa insinööriyössä Verkkoanalytiikka ja Google Analytics verkkoliiketoiminnan menestyksen mittareina (Paavolainen 2015).

1.2 Rajaukset

Käsittelen mediapanostusten vaikutuksia liiketoiminnan rahallisten tavoitteiden näkökulmasta. Siksi en ota huomioon huomioarvo- ja mielikuvamittareita, joita usein käytetään kuvaamaan mainonnan tuloksellisuutta varsinkin perinteisissä medioissa (printti, tv, radio, ulkomainonta). Käsittelen mainonnan vaikuttavuuden mittaamista tässä työssä ainoastaan digitaalisen mainonnan näkökulmasta.

Oma ja ansaittu media ovat digitaalisen markkinoinnin osia ja vaikuttavat myös konversion, eli mainostajan verkkosivustolla tavoitteleman toimenpiteen syntymiseen. Konversio voi olla esimerkiksi ostos verkkokaupassa tai yhteydenottopyyntö. Varsinkin ansaitun median sisällyttäminen attribuutiomallinnukseen on kuitenkin teknisesti käytännössä mahdotonta, jonka vuoksi keskityn tässä työssä käsittelemään ainoastaan ostetun median vaikuttavuuden mittaamista.

Attribuutiomallinnusta ja web-analytiikkaa on mahdollista tehdä monella eri alustalla. Tässä opinnäytetyössä havainnollistan kaikki esimerkit käyttäen Google Analyticsin maksutonta versiota, joka on yksi käytetyimpiä web-analytiikkatyökaluja kirjoitushetkellä. Kerron tarkemmin web-analytiikkatyökalujen ja mainonnanhallintajärjestelmien eroista attribuutiomallinnuksessa sekä käytettävän alustan valinnassa huomioon otettavista tekijöistä tuotososassa.

1.3 Keskeiset käsitteet ja lyhenteet

Tässä luvussa selitän lyhyesti työssä käytetyt keskeiset käsitteet ja lyhenteet aakkosjärjestyksessä, jotta lukija voi palata tarkistamaan käsitteitä lukiessaan.

A/B-testaus ja monimuuttujatestaus ovat testausmenetelmiä, joiden avulla testataan erilaisia versioita esimerkiksi laskeutumissivusta tai painikkeista. Sivustolle tuleva

liikenne jaetaan tasan testiversioiden kesken, ja parhaiten toiminut versio otetaan käyttöön.

Analyysi-ikkuna (lookback-window) määrittää, kuinka pitkältä ajalta kosketuspisteet huomioidaan konversion syntymisessä. Oletusarvoisesti analyysi-ikkuna on Google Analyticsissa 30 päivää.

Attribuutiomallinnus, vaikuttavuuden mallinnus, on web-analytiikan osa-alue, jonka avulla tutkitaan eri kanavien roolia konversiopolussa. Onnistuneen mallinnuksen avulla mainosbudjetti voidaan allokoida kustannustehokkaammin tavoitteiden saavuttamiseksi.

Avainmittari (KPI, key performance indicator) on luku, jolla mitataan markkinoinnin ja myynnin päätavoitteita tietyssä ajanjaksona. KPI voi olla esimerkiksi keskiostoksen kasvu tai klikkiprosentti.

CLV (customer lifetime value) on asiakkaan elinkaaren arvo, ja se kuvaa kuinka paljon tietty asiakas tuottaa liikevaihtoa tai -voittoa asiakkuutensa aikana.

Eväste (cookie) on päätelaitteeseen tallentuva tekstitiedosto, jonka avulla käyttäjää voidaan seurata internetissä, ja tunnistaa myöhemmin tämän palatessa sivustolle. Yksi eväste mittaa aina yhden henkilön yhden päätelaitteen yhden selaimen toimintaa.

Google Analytics (GA) on selaimessa toimiva maksuton tietokone-ohjelma, jolla kerätään tietoa verkkosivustosta ja siellä vierailevista kävijöistä.

Google Analytics Premium on Google Analyticsin maksullinen versio, joka muun muassa mahdollistaa suuremman tietomäärän käsittelyn.

Google Tag Manager (GTM) on Googlen ilmainen selaimessa toimiva työkalu, jolla mahdollistetaan verkkosivuston tagien ja niiden laukaisusääntöjen vaivaton hallinta.

Hakukonemainonta (PPC, SEA, SEM) on mainontaa, jossa mainokset ovat tekstimuotoisia, ja näkyvät hakutulosten yhteydessä hakukoneessa.

Kiitos-sivu on sivu, joka näytetään esimerkiksi verkkokaupan asiakkaalle onnistuneen oston jälkeen. Konversioita voidaan mitata asettamalla mainonnanhallinta- tai analytiikkaohjelmiston tägi kiitos-sivulle.

Klikkaus on tapahtuma, jossa verkkosivuja selaava käyttäjä napsauttaa toiselle sivulle ohjaavaa linkkiä, joka voi olla esimerkiksi mainoksessa.

Klikkiprosentti (CTR, click-through-rate) tarkoittaa prosenttilukua, joka saadaan jakamalla klikit näyttöjen määrällä. Esimerkiksi 100 000 näyttöä ja 2 500 klikkiä keränneen kampanjan klikkiprosentti on 2,5%.

Konversio on tulos toimenpiteestä, jonka mainostaja haluaa käyttäjän sivustolla tekevän. Tyypillisiä konversioita ovat esimerkiksi ostos verkkokaupassa, esitteen tilaus tai yhteydenottopyyntö.

Konversioaste (conversion rate) on suhdeluku, joka saadaan jakamalla kaikki toteutuneet tulokset vierailuiden kokonaismäärällä tietynä ajanjaksona.

Konversio-optimointi (CRO, conversion rate optimization) tarkoittaa kaikkia niitä toimenpiteitä, joilla konversioiden määrää, laatua ja konversioastetta pyritään kasvattamaan.

Kosketuspisteet ovat mainosviestejä, joita käyttäjä kohtaa ennen konversiota. Myös suora liikenne ja orgaaniset hakutulokset luetaan kosketuspisteiksi.

Laskeutumissivu (landing page) on sivu, johon käyttäjä päätyy klikattuaan mainosta.

Laukaisusäätö (trigger) määrittää, milloin sivustolle asennettu tägi lähettää tietoja kolmannelle osapuolelle, esimerkiksi Google Analyticsiin.

Mainonnanhallintajärjestelmä (ad serving system) on selaimessa käytettävä ohjelmisto, joka mahdollistaa mainosten jakelun eri sivustoille, kampanjaseurannan ja raportoinnin.

Mainosnäyttö (impression) lasketaan, kun mainos latautuu verkkosivun mukana, ja käyttäjällä on mahdollisuus nähdä mainos.

ROAS (return on advertising spend) on mainonnan tehoa kuvaava luku, joka lasketaan jakamalla mainospanostuksella saatu tuotto mainonnan kokonaiskustannuksella, joka yleensä koostuu media- ja tuotantokustannuksista.

ROI (return on investment) on luku, jolla kuvataan investoidun rahan tehokkuuden takaisinmaksuaikaa tiettyyn investointikohteeseen. Luku lasketaan jakamalla nettotuotto investoinnin suuruudella.

ROMI (return on marketing investment) kuvaa markkinointi-investointien tuottoa. Luku lasketaan samalla tavalla kuin ROI, mutta siinä otetaan huomioon vain markkinoinnin ja myynnin investoinnit ja tuotot.

Tägitys tarkoittaa seurantapisteiden asettamista sivuston koodiin tai mainoksiin, jolloin niistä kertyy tietoa kolmannelle osapuolelle, esimerkiksi web-analytiikkajärjestelmään. Sivuston tägitys toteutetaan asettamalla javascript-koodinpätkä verkkosivuston jokaisen sivun lähdekoodiin. Mainosten tägitys tapahtuu esimerkiksi yksilöimällä niiden URL-osoitteet eri muuttujien avulla.

Universal Analytics on Google Analyticsin uusin versio, johon on mahdollista kerätä tietoa selainten ja mobiilisovellusten lisäksi suoraan internetyhteydessä olevista päätelaitteista, esimerkiksi kassajärjestelmistä.

2 Digitaalisen mainonnan mittaus

2.1 Digitaalisen mainonnan mittauksen keinot

Digitaalisen markkinoinnin kokonaisuuden muodostavat oma, maksettu ja ansaittu media. Digitaalisella mainonnalla tarkoitetaan maksettua näkyvyyttä internetissä, ja sen kanavia ovat esimerkiksi display- ja hakukonemainonta. (Chaffey & Smith 2013, 33.)

Digitaalista mainontaa voidaan mitata eri keinoin, jotka voidaan jakaa primääriseen ja sekundaariseen tiedon keruuseen. Primäärisen tiedon keruu tehdään itse, ja sen keinoja ovat esimerkiksi paneelitutkimus, kyselyt, fokusryhmätutkimukset ja käytettävyytestit, sekä web-analytiikka joka muodostuu verkkopalvelin- ja selainpohjaisesta analytiikasta. Sekundaarisella tiedolla tarkoitetaan valmiita, ulkopuolisten toimijoiden julkaisemia tutkimuksia ja tilastoja. (Chaffey & Smith 2013, 202.)

Attribuutiomallinnus on osa selainpohjaista web-analytiikkaa, jossa käyttäjän toimintaa mitataan evästeillä, Javascript-koodinpätkillä ja muokatuilla URL-osoitteilla, jotka lähettävät tietoa web-analytiikkaohjelmistoon tiedon analysoimista varten.

Yksi markkinoinnin suurimmista haasteista on selvittää, kuinka markkinoinnin kustannukset tulisi jakaa eri tuotteille ja markkinointikanaville liiketoiminnallisiin tavoitteisiin pääsemiseksi. Haasteena on myös selvittää, kuinka eri strategiset päätökset, kuten muutokset budjetissa, vaikuttavat tavoitteisiin pääsemiseen. (MEC Global 2015, 3.) Näihin kysymyksiin vastaamiseksi on kehitetty erilaisia mallinnusmenetelmiä, jotka voidaan jakaa makro- ja mikrotason haasteita mittaaviin menetelmiin.

Makrotason menetelmiä kutsutaan ekonometrisiksi menetelmiksi, joita ovat esimerkiksi markkinointi-mixin mallinnus, brändipääoman mallinnus ja pitkän aikavälin mallinnus. Näiden menetelmien avulla päästään selville muun muassa pitkän aikavälin trendeistä, eri mediaryhmien (TV, radio, online, printti, ulkomainonta) välisestä budjettijaosta, sekä tunnettuuden tavoitetasoista. Digitaalinen attribuutiomallinnus on mikrotason menetelmä, joka pyrkii vastaamaan taktiseen kysymykseen siitä, kuinka budjetti tulisi jakaa kustannustehokkaimmin eri digitaalisten kanavien välillä. Nämä menetelmät täydentävät toisiaan, ja ovatkin tehokkaimpia yhdessä käytettynä. (MEC Global 2015, 5.)

2.2 Digitaalisen attribuutiomallinnuksen määritelmä ja käyttötarkoitus

Ihmisten digitaalinen ostokäyttäytyminen on erilaista. Toiset tulevat suoraan verkkosivulle ja ostavat välittömästi, toiset taas vierailevat sivustolla useita kertoja tietyn ajanjakson aikana ennen konversiota. (Chaffey & Smith 2013, 112-113.)

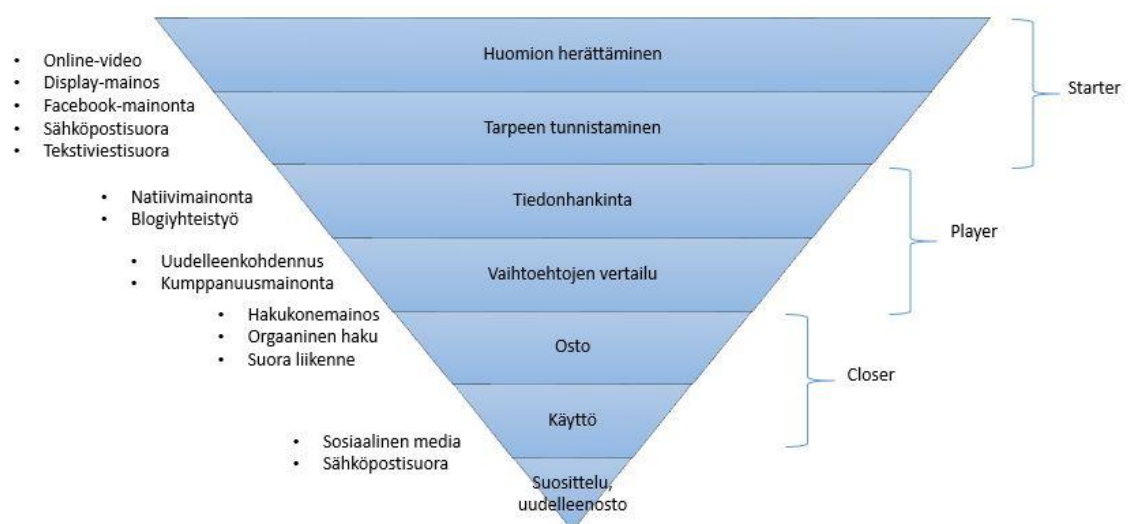
Ostoprosessin aikana kuluttaja kohtaa display- ja hakukonemainontaa, saa uutiskirjeitä sähköpostiinsa, ja näkee brändiviestin esimerkiksi sosiaalisessa mediassa tai blogissa. Attribuutiomallinnus pyrkii osoittamaan, mitkä näistä kanavista ovat olleet tärkeimmät tavoitteen, konversion syntymisen, kannalta. (Chaffey & Smith 2013, 112-113.) Konversion arvo luetaan eri kanavien ansioksi sen mukaan, kuinka ratkaisevia ne ovat olleet tuloksen kannalta (Tenkanen 2013).

Attribuutiomallinnuksella markkinoija pyrkii tarkastelemaan kaikkia konversion syntymiseen vaikuttaneita kanavia kokonaisuutena tiettyä ajanjaksona. Tämä tulisi mieltää jatkuvana prosessina, jonka tavoitteena on luoda mainostaja- ja toimialakohtaiset tarpeet huomioiva, painotettu attribuutiomalli kuvaamaan tilannetta mahdollisimman tarkasti. (IAB Finland 2015.)

Huomioitavaa on, että jos kuluttajan polku konversioon on yksinkertainen ja suurin osa vierailijoista konvertoituu heti, tarvetta attribuutiomallinnukselle ei välttämättä ole. Nyrkkisääntönä voidaan todeta, että jos enemmän kuin kolme neljäsosaa vierailijoista konvertoituu vieraillessaan sivustolla ensimmäisen kerran, attribuutiomallinnuksen tekeminen ei ole välttämättä kovin tärkeää. (Chaffey & Smith 2013, 117.)

2.2.1 Attribuutiomallinnuksen rooli mediasuunnittelussa

Internet-mainonnan eri kanavat voidaan luokitella starter-, player- ja closer –tyyppisesti. Starter on ensimmäinen kuluttajan kohtaama mainosviesti, ja closer viimeinen kosketuspiste ennen konversiota. Player -luokkaan luokitellaan kaikki näiden välissä olevat kosketuspisteet. Yleisesti ottaen display-mainonta toimii kiinnostuksen herättäjänä starter- ja player-luokissa, kun taas esimerkiksi hakumainonta ja suora liikenne toimivat paremmin closerina. (Relander 2013, 104-105.)



Kuvio 1. Digitaalisen mainonnan eri kanavat toimivat eri osissa ostoprosessia. (Mukaillen Leino 2013.)

Kuviossa 1. on havainnollistettu karkeasti eri kanavien roolit digitaalisessa ostoprosessissa. Koska jokaisella mainostajalla ja toimialalla on oma ostoprosessinsa,

on tämä malli käytännössä hyvin yksilöllinen. Esimerkiksi auton ostoprosessi on erilainen kuin päivittäistavaratuotteen, joten myös niiden mainonnassa käytettävät kanavat ovat hyvin erilaisia. (Chaffey & Smith 2013, 127-128.)

Attribuutiomallinnuksella pyritään saamaan selville kunkin käytetyn kanavan rooli konversiopolussa. Onnistuneella mallinnuksella voidaan saada tukea päätöksentekoon ja allokoita mediabudjetti kustannustehokkaammin. KPI-mittareista erityisesti mainospanostusten tuottavuutta kuvaavaa ROAS-lukua seuraamalla voidaan päästä selville allokoinnin tehostumisesta pitkällä aikavälillä, joskaan luku ei aina suoraan kerro juuri attribuutiomallinnuksen panoksesta.

2.2.2 Konversio

Jokaisen verkkosivuston olemassaolon perustana tulisi olla jokin vierailijan tekemä mitattava toiminta. Mitattava toiminta, konversio, voi olla myynnin lisäksi esimerkiksi uutiskirjeen tilaus, yhteydenottopyyntö, rekisteröityminen tai päätyminen tietylle sivulle sivuston sisällä. (Kaushik 2007, 364.)

Sivustolla voi olla yksi tai useampia mitattavia tavoitteita. Tavoitteet täyttäneitä käyttäjiä kutsutaan konvertoituneiksi käyttäjiksi (Hyvönen 2015, 3). Konversiot voidaan jakaa makro- ja mikrokonversioihin sen mukaan, mikä niiden merkitys on liiketoiminnassa. Tärkeintä tavoitetta, esimerkiksi verkkokaupassa ostotapahtumaa, tulisi mitata makrokonversiona. Makrokonversioon johtavia muita sivustolla olevia toiminnallisuuksia, kuten rekisteröitymistä kutsutaan mikrokonversioiksi. Myös niiden tunnistaminen ja mittaaminen on tärkeää, jotta esimerkiksi puutteet sivuston toiminnassa voitaisiin huomata ja korjata. (Kaushik 2008) Verkkokaupassa mikrokonversioksi voidaan asettaa esimerkiksi tuotteen lisäys ostoskoriin ja makrokonversioksi onnistunut osto.

Konversioasteella tarkoitetaan kaikkia toteutuneita tuloksia jaettuna vierailujen määrällä tiettyinä ajanjaksona (Kaushik 2010, 55). Konversioaste esitetään prosenttilukuna: jos esimerkiksi sivustolla on tiettyinä ajanjaksona ollut 100 vierailua, ja tuloksena kaksi konversiota, on konversioaste tuolloin 2%.

Konversio-optimoinnilla pyritään kasvattamaan konversioastetta, ja sen tulisi olla jatkuva prosessi. Yleisesti ottaen konversio-optimoinnissa keskitytään sivuston käytettävyyden

parantamiseen esimerkiksi A/B-testauksella, mutta myös ulkoiset tekijät, kuten laadukkaan liikenteen lähteet tulisi tunnistaa ja huomioida.

Attribuutiomallinnus voidaankin mieltää osaksi konversio-optimointia eli konversioiden määrän ja laadun kasvattamista, koska mediavalintoja tehtäessä tulisi ymmärtää, mitkä kanavat herättävät kuluttajan kiinnostuksen, syöttävät liikennettä muihin kanaviin ja auttavat lopulta konversion syntymisessä. Pelkkien konversioiden määrän laskemisen lisäksi tulisi mitata myös niiden laatua, esimerkiksi keskiostoksen suuruutta, asiakasuskollisuutta ja arvoa (Pyyhtiä 2013b, 47).

Konversioasteen muuttuminen itsessään ei vielä kerro kaikkea liiketoiminnan tilasta, vaan se tulisi aina esittää kontekstissa. Sivuston vierailijoiden määrän, liikevaihdon ja myyntituloksen tarkastelu yhdessä konversioasteen kanssa antaa jo hyvän pohjan johtopäätöksille pelkän konversioasteen seuraamisen sijaan. (Kaushik 2007, 173.)

2.2.3 Käytettävyys ja A/B-testaus

Konversion syntymiseen vaikuttaa ratkaisevasti käytettävyys. Käytettävyydellä tarkoitetaan verkkopalvelun helppokäyttöisyyttä ja käyttäjälle muodostuvaa käyttökokemusta. Käytettävyys muodostuu verkkopalvelussa muun muassa siitä kuinka siellä navigoidaan, etsitään, klikkaillaan painikkeita, täytetään lomakkeita, lisätään tuotteita ostoskoriin ja suoritetaan maksutapahtuma. (Vastamäki 2013, 122.)

Käytettävyyden arvioimisessa käytetään usein laadullisia käytettävyystestejä, joissa pieni määrä testikäyttäjiä suorittaa verkkopalvelussa tehtäviä ja raportoi samalla käytettävyysongelmista. Muita keinoja arvioida käytettävyyttä ovat asiantuntija-arviointi, käyttäjä tutkimus, yksilöhaastattelu, fokusryhmätutkimus ja kyselyt. (Vastamäki 2013, 126.)

Verkkopalvelun käytettävyyteen liittyviä asioita voidaan mitata myös teknisestä näkökulmasta web-analytiikalla. Esimerkiksi Google Analytics -mittaustyökalussa voidaan päästä selville sivuston nopeudesta sivuston nopeus -raporttien (site speed) avulla.



Kuvio 2. Sivuston nopeuden yleiskatsaus Google Analyticsissa.

Nämä raportit kertovat sivujen latausajan, uudelleenohjausajan, yksittäisten toimintojen suoritusnopeuden ja latausajan (esimerkiksi painikkeen klikkaus, kuvan latautuminen), keskimääräisen palvelinyhteys- ja vastausajan ja nopeuden, jolla selain järjestää asiakirjan käyttäjän vuorovaikutusta varten (Google 2015).

Muita käytettävyyden mittauksessa hyödynnettäviä raportteja voivat tilanteesta riippuen olla esimerkiksi välitön poistumisprosentti (bounce rate), poistumisprosentti (exit rate), keskimääräinen istunnon kesto (avg session duration), ja käyttäjäliikenne (users flow).

Jos esimerkiksi havaitaan, että huomattava osuus käyttäjistä onnistuu verkkokaupassa lisäämään tuotteet ostoskoriin, mutta poistuu ennen maksutapahtumaa, voidaan päätellä sivun käytettävyydessä olevan jokin ongelma. Tällaiset havainnot voidaan varmistaa käytettävyydesteillä, ja ongelma voidaan ratkaista esimerkiksi A/B-testauksella.

A/B-testauksella ja monimuuttujatestauksella tarkoitetaan testausmenetelmiä, joiden avulla testataan erilaisia versioita esimerkiksi laskeutumissivusta tai sivun yksittäisistä osista, esimerkiksi kuvista tai painikkeista. Sivustolle tuleva liikenne jaetaan tasan testiversioiden kesken, jolloin niiden toimivuutta voidaan arvioida suhteessa tavoitteisiin. Parhaiten toiminut versio otetaan käyttöön sivustolla, ja testausta jatketaan yhä uusilla versioilla tai eri toimintoja testaamalla. (Pyyhtiä 2013a, 199.)

2.3 Verkkomainonnan mittaamisen haasteet

Verkkomainonnan mittaamiseen liittyy monta teknistä haastetta, jotka tulisi tiedostaa ennen mittausta ja varsinkin tehtäessä johtopäätöksiä tulosten perusteella. Kirjoitushetkellä suurimmat haasteet liittyvät evästeisiin, todennettuihin mainosnäyttöihin, mainostenesto-ohjelmiin ja botteihin. Haasteita aiheuttavat myös analyysivaiheen tilastolliset menetelmät, jotka väärin käytettyinä voivat aiheuttaa vääriä johtopäätöksiä. Kaikki nämä haasteet vaikuttavat osaltaan myös attribuutiomallinnuksen tarkkuuteen ja paikkansapitävyyteen.

2.3.1 Ihmiset, selaimet ja evästeet

Verkkomainonnan mittaamisessa yksi suurimmista haasteista on erottaa toisistaan ihmiset, selaimet ja evästeet. On virheellistä olettaa että analytiikkaohjelmistossa näkyvä vierailijoiden määrä tarkoittaisi automaattisesti todellista ihmisten määrää. Analytiikkaohjelmistot laskevat selaimia, joiden toistuvat vierailut tunnistetaan selaimiin tallennettujen evästeiden avulla. Yksi eväste, eli päätelaitteeseen tallentuva tekstitiedosto, mittaa aina yhden henkilön yhden päätelaitteen yhden selaimen toimintaa. Usein yhdellä ihmisellä on kuitenkin käytössä useita eri päätelaitteita ja selaimia. (Roponen 2013, 74.)

Jos esimerkiksi yksi ihminen käyttää kotitietokoneellaan, älypuhelimellaan ja tablettitietokoneellaan yhtä selainta sekä työkoneellaan kahta, analytiikkaohjelmisto mittaa tämän käyttäjän viitenä eri evästeenä. Jos käyttäjä poistaa selaimistaan evästeet tai ne poistuvat automaattisesti säännöllisin väliajoin, selaimeen tallentuu uudet evästeet. Kyseinen käyttäjä saattaa siis näkyä analytiikassa esimerkiksi kymmenenä eri evästeenä tietyn aikajakson sisällä. (Roponen 2013, 74.) Nämä evästeet on teknisesti mahdotonta yhdistää tiettyyn käyttäjään, ellei tämä ole tunnistaunut verkkopalveluun (esimerkiksi kirjautumalla sisään) jokaisella käyttämällään päätelaitteella ja selaimella (Kaushik 2012).

Lisäksi yhden laitteen yhtä selainta saattaa käyttää useampi kuin yksi ihminen, jolloin todellisen konversiopolun selvittäminen ja käyttäjien erottaminen toisistaan vaikeutuu entisestään. Internet-mainonnan mittauksessa tulee siis aina huomioida, että evästeiden määrä ei kuvaa tarkasti todellisten käyttäjien määrää.

2.3.2 Mainostenesto-ohjelmat, todennetut mainosnäytöt ja botit

Mainostenesto-ohjelmat eli adblockerit vaikeuttavat entisestään internet-mainonnan tehon arviointia. Suomalaisista internetin käyttäjistä noin 19% käyttää mainostenesto-ohjelmaa, globaalisti tällaisten ohjelmien käyttö kasvoi vuosien 2014 ja 2015 välillä 41% (Adobe 2015). Mainostenesto-ohjelmat asettavat mainostajille haasteen tehdä relevantimpaa mainontaa, joka ei saa käyttäjiä harkitsemaan mainosten estämistä. Tämä tarkoittaa, että mainonnan tulisi olla paremmin kohdennettua, luovien materiaalien paremmin suunniteltuja ja toisto rajoitettuna kohtuulliseksi. Myös natiivimainonnalla eli

maksetulla sisältömarkkinoinnilla voidaan kiertää mainostenesto-ohjelmien luomia haasteita. (Norman 2015.)

Merkittävä osa mainosnäytöistä latautuu esimerkiksi sivun alaosaan, tai ei ehdi latautua ollenkaan. Siitä huolimatta nämä näytöt lasketaan ja veloitetaan mainostajalta. Todennetulla mainosnäytöllä tarkoitetaan mainosnäyttöä, joka on näkynyt käyttäjän ruudulla. IAB:n laatiman standardin perusteella todennettu mainosnäyttö lasketaan, kun vähintään 50% mainoksesta on näkynyt vähintään yhden sekunnin ajan käyttäjän ruudulla. Tämä laskutapa on mainostajan näkökulmasta hieman ongelmallinen varsinkin pienempien mainosformaattien kohdalla, sillä käyttäjä ei välttämättä ehdi huomata mainoksia vaikka ne olisivatkin vilahtaneet näytöllä sivustoa selattaessa.


IMPRESSIONS	VIEWABLE (%)	AVG. VIEWABILITY TIME (SEC.)
204 401	25,97%	7,38

Kuvio 3. Kuvakaappaus Adform-mainonnanhallintajärjestelmän raportista, joka osoittaa että erään kampanjan mainosnäytöistä vain noin 26% on oikeasti näkynyt käyttäjien ruuduilla.

Attribuutiomallinnusta tehtäessä todennettujen mainosnäyttöjen määrää ja osuutta kannattaa seurata tarkasti. Esimerkiksi display-mainonnan todellista tehoa konversiopolussa on mahdoton arvioida luotettavasti, jos näytöistä suuri osa ei oikeasti tavoita ketään. Todennettujen mainosnäyttöjen osuutta voi kasvattaa esimerkiksi ostamalla mainosnäyttöjä julkaisijoilta, jotka lupaavat todennettujen mainosnäyttöjen takuun.

Vuoden 2015 lopussa ihmisten tuottama liikenne oli 51,5% kaikesta internet-liikenteestä. Loput liikenteestä tuottivat botit eli sovellukset, jotka suorittavat automaattisesti tehtäviä internetissä. (Zeifman 2015.) Botit voidaan jakaa hyviin ja huonoihin botteihin. Hyvät botit mahdollistavat muun muassa hakukoneiden ja RSS-syötteiden toiminnan, sekä pörssikurssien, säätietojen ja valuuttakurssien automaattisen päivityksen reaaliajassa. Huonot botit puolestaan esimerkiksi kaappaavat selaimia, lähettävät roskapostia, selaavat sivustoja tuottaen turhia sivulatauksia ja mainosnäyttöjä, sekä klikkailevat mainoksia. (Shaw & Tsemekhman 2014.)

2012-2015 Traffic Breakdown by Visitor Type



Kuvio 4. Internet-liikenteen viime vuosien kehitys kävijätyypin mukaan (Zeifman 2015.)

Huonojen bottien osuus kaikesta verkkoliikenteestä on ollut tasaisesti noin 30% sivuston koosta riippumatta, joskin viime vuosina osuudessa on tapahtunut pientä laskua (Zeifman 2015). Lasku voi selittyä esimerkiksi sillä, että eri teknologiatoimittajat, kuten Google, ovat ryhtyneet aktiivisesti kehittämään ratkaisuja huonojen bottien havaitsemiseksi ja estämiseksi. Esimerkiksi Google Analyticsissa huonoa bottiliikennettä voidaan suodattaa pois raporteista automaattisesti, kun tämä ominaisuus otetaan käyttöön tilin asetuksissa. (Moore 2015.)

2.3.3 Attribuutiomallinnuksen haasteet

Attribuutiomallinnuksen suurimmat heikkoudet liittyvät tulosten analysoinnissa käytettyihin tilastollisiin menetelmiin ja niiden pohjalta tehtäviin suosituksiin. Vaikka esimerkiksi mallinnuksen perusteella vaikuttaisi, että display-mainonnan näkeminen

ohjasi tietyn tyyppisiä kuluttajia myöhemmin verkkosivustolle hakukoneen kautta, voi todellinen syy olla jokin muu. Nämä kuluttajat ovat esimerkiksi saattaneet suositella tuotetta tai palvelua toisilleen keskustelupalstalla, eikä display-mainonnan budjettiosuuden kasvattamisella ole tällöin ollut mitään vaikutusta myyntiin.

Tällaisia syy-yhteyksiä ei voida selvittää web-analytiikalla, mutta sen tarjoamaa tietoa voidaan täydentää esimerkiksi kyselytutkimuksilla, joilla selvitetään sosiaalisten suhteiden vaikutuksia ostopäätöksiin (Korpi 2013, 147).

Taulukko 1. Nelikenttäanalyysi attribuutiomallinnuksen ominaisuuksista mainostajan näkökulmasta.

Vahvuudet <ul style="list-style-type: none"> • Mittaustarkkuus parempi kuin perinteisissä medioissa • Mahdollistaa mediabudjetin tehokkaamman allokoinnin 	Heikkoudet <ul style="list-style-type: none"> • Mittauksen täydellistä tarkkuutta rajoittavat tekniset haasteet • Käytettävä malli • Mittauksen sitomat resurssit
Mahdollisuudet <ul style="list-style-type: none"> • Yhdistettävissä muiden tutkimusmenetelmien tuottamiin tuloksiin 	Uhat <ul style="list-style-type: none"> • Väärien johtopäätösten ja suositusten tekeminen analysointivaiheessa • Käytettävä attribuutiomenetelmä on julkaisijoiden tiedossa

Attribuutiomallinnuksen suurin vahvuus on sen mahdollistama tieto konversiopolusta kokonaisuutena, ja kun tämä tieto liitetään muiden tutkimusmenetelmien tuloksiin voidaan päätöksiä tehdä yhä luotettavampaan tietoon perustuen. Vaikka mittaustarkkuus on huomattavasti parempi kuin perinteisissä medioissa, ei attribuutiomallinnus kuitenkaan kykene tarjoamaan täydellisen tarkkoja tuloksia monien teknisten haasteiden takia.

Mittauksen tekijöiden osaamistaso määrittää hyvin paljon suositusten onnistumista. Jos mittauksen tekijä käyttää vääränlaista attribuutiomallia, tulkitsee tuloksia väärin tai jättää huomioimatta mahdollisen korrelaation tai kausaation, mittauksen perusteella tehtävät johtopäätökset voivat olla varsinaisten tavoitteiden vastaisia.

Jos mainostajan käyttämä attribuutiomalli on mainosinventaaaria myyvän julkaisijan tiedossa, voi tämä hyötyä tiedosta ajoittamalla ostetut mainosnäytöt siihen kohtaan mainostajan konversiosykliä, josta julkaisija itse todennäköisesti hyötyy eniten. Jos esimerkiksi on tiedossa että mainostaja jakaa konversion arvon viimeisen kosketuspisteen perusteella, julkaisija voi kohdentaa mainosnäyttöjä suurella toistolla vain saadakseen mahdollisimman paljon konversioiden arvosta itselleen. (Berman 2015, 17.)

Attribuutiomallinnuksen haasteiden takia on alettu kehittämään edistyneempiä attribuutiomenetelmiä. Nämä menetelmät käyttävät esimerkiksi peliteoriaan perustuvia algoritmeja laskemaan reaaliajassa, kuinka paljon juuri mainospanostukset vaikuttavat myyntiin sekä analysoimaan myös käyttäjiä, jotka mainosten näkemisestä tai klikkauksesta huolimatta eivät päätyneet konversioon (Business Wire 2013). Tällaisia edistyneisiin matemaattisiin malleihin perustuvaa menetelmiä hyödyntävät ohjelmistokehittäjistä kirjoitushetkellä muun muassa Google Analytics Premium ja Abakus.

3 Yhteenveto

3.1 Johtopäätökset ja suositukset

Suurimmat hyödyt attribuutiomallinnuksesta saadaan, kun se toteutetaan systemaattisesti, jatkuvana prosessina. Vaikka konversioksi voidaan asettaa lähes mikä tahansa sivulla tehtävä toiminta, brändimainostaja hyötyy mallinnuksesta vähemmän jo pelkästään sen sitomien resurssien takia. Erityisen paljon mallinnuksesta voivat hyötyä toimialat ja yritykset, joiden liiketoiminta ja mainospanostukset keskittyvät kokonaan tai lähes kokonaan verkkoon.

Attribuutiomallinnusta tulisi käyttää markkinoinnin päätöksenteon tukena, mutta sen ei tulisi olla ainoa päätöksentekoon vaikuttava tekijä. Pelkästään jo luvussa 2.3 esitettyjen haasteiden takia voidaan todeta, ettei attribuutiomallinnus pysty kuvaamaan konversion syntymiseen johtaneita tekijöitä täydellisen tarkasti. Mallinnus voi kuitenkin tuoda kilpailuetua, kun päätöksenteon tueksi otetaan sen lisäksi muita menetelmiä, kuten esimerkiksi ekonometrinen mallinnus tai kvalitatiiviset käyttäjätutkimukset, riippuen liiketoiminnan tavoitteista ja toimialasta.

Mallinnuksen toteutus kertaluontoisena, esimerkiksi kuvaamaan yhden yksittäisen kampanjan tehoa, ei ole mielestäni tarkoituksenmukaista. Samalle liiketoiminnalle saattaa toimia samaan aikaan erilaiset mallit, ja esimerkiksi puoli vuotta sitten toiminut malli ei välttämättä toimi enää nykyhetkessä sellaisenaan. Todelliset hyödyt mallinnuksesta saadaan, kun attribuutiomallinnusta työestetään jatkuvana prosessina.

Tehokkaan attribuutiomallinnuksen mahdollistaa huolellinen ja päämäärätietoinen mittauksen suunnittelu, jossa tavoitteet, avainmittarit ja niiden tavoitetasot on määritelty tarkasti. Kun suunnitelman perusteella mallin toimivuutta seurataan ja optimoidaan kuukausittain, ja onnistumista arvioidaan kriittisesti kvartaaleittain, pystytään löytämään mahdolliset kausivaihtelut omassa liiketoiminnassa ja attribuutiomallin toimivuudessa. Tällainen systemaattinen tekeminen saattaa tuottaa ratkaisevan kilpailuedun pitkällä aikavälillä.

Vaikka attribuutiomallinnuksella ei ole mahdollista päästä täydelliseen lopputulokseen, se auttaa ennen kaikkea hahmottamaan mainospanostusten kokonaisuutta (Kaushik 2012).

3.2 Jatkotutkimusaiheet

Tämä työ esitteli attribuutiomallinnuksen perusteet, haasteet, toteutuksen eri vaiheet sekä lähtökohdat tiedon tarkasteluun ja hyödyntämiseen päätöksenteossa.

Jatkotutkimusaiheena, esimerkiksi toiminnallisena opinnäytetyönä esitän tehtäväksi tutkimuksen siitä, kuinka paljon mitäkin mediapanostusta voi todellisuudessa kasvattaa attribuutiomallinnuksen perusteella toimiviin kanaviin, ennen kuin niistä saatava hyöty saavuttaa huippunsa. Tutkimuksen avulla päästäisiin selville siitä, minkä suuruisella lisäpanostuksella mediarahalle ei enää saada vastinetta tietyn toimialan tietyssä yrityksessä.

Aihetta voisi tarkastella esimerkiksi toimeksiannon kautta, jossa konversioiden määrää ja laatua pyrittäisiin kasvattamaan attribuutiomallinnuksen avulla esimerkiksi vuoden ajan. Tällöin ehdittäisiin kartoittaa alkutilanne ja muodostaa hypoteesi, jonka perusteella mittaus aloitettaisiin. Tuloksia tarkasteltaisiin säännöllisesti ja mallia muokattaisiin tarpeen vaatiessa. Lopulta olisi mahdollista luoda hyvin käsitys toimialan tai yrityksen

konversiopolusta ja toimivimmasta mediabudjetin allokoinnista toimeksiantajan käyttöön.

Myös perinteisen median, esimerkiksi printti- ja tv-mainonnan, sisällyttäminen digitaaliseen analytiikkaan, sekä niiden mittaaminen nimenomaan tuloksellisuuden näkökulmasta olisi mielenkiintoinen aihe opinnäyte- tai pro gradu -työlle. Lisäksi voitaisiin vertailla eri ohjelmistotoimittajien tarjoamien ratkaisujen ja tilastollisten menetelmien eroja käytännössä.

3.3 Kirjoitusprosessi

Tavoitteenani oli kirjoittaa opinnäytetyö attribuutiomallinnuksen peruseräiteistä ja sen roolista verkkomainonnan tuloksellisuuden mittaamisessa. Aihe osoittautui todella haastavaksi. Työn edetessä kävi nopeasti selväksi, ettei aihetta voi käsitellä sellaisenaan irrallisena, vaan että työssä pitää käsitellä myös esimerkiksi mittauksen suunnittelun ja teknisen toteutuksen perusteet ja haasteet. Jälkikäteen ajateltuna työ olisi kannattanut kirjoittaa englanniksi, sillä käsitteiden suomenkielisten vastineiden löytäminen oli vaikeaa.

Aluksi näkökulman löytäminen oli hankalaa, ja lopulta oppaan laatiminen toiminnallisena opinnäytetyönä tuntui luonnollisimmalta ratkaisulta. Vaikka suunnittelin työtä huolellisesti etukäteen, työn edistyminen oli hidasta päivätyön vuoksi. Työstäminen oli katkonaista ja ajoittui lähes poikkeuksetta vain viikonlopuille, mikä osaltaan vaikutti lopputulokseen. Olen kuitenkin tyytyväinen työhön ottaen huomioon aiheen ja kirjoitusprosessin haasteet.

Alkuperäinen suunnitelmani oli tässä työssä käsitellyiden aiheiden lisäksi tehdä attribuutiomallinnusprojekti jollekin toimeksiantajalle. Työn edetessä osoittautui kuitenkin, että pelkästään tämä teoriaosuus ja mallinnusprosessin kuvaus olisivat jo sellaisenaan riittävän suuri kokonaisuus opinnäytetyöksi. Lisäksi en välttämättä olisi pystynyt toteuttamaan onnistunutta mallinnusprojektia, ellen olisi etukäteen tutustunut näin laajasti perusteisiin.

3.4 Arvio työstä

Mielestäni saavutin työlle asettamani tavoitteet, ja tämän työn perusteella kohderyhmääni kuuluva lukija pystyy ymmärtämään attribuutiomallinnuksen perusteet, haasteet ja toteutuksen vaiheet.

Tärkeimmät itse oppimani asiat olivat ymmärrys eri kanavien tehtävistä ostoprosessissa sekä attribuutiomallinnuksen roolista markkinoinnin päätöksentekoon tukea tarjoavana yksittäisenä keinona. Opin myös paljon yksityiskohtia verkkoanalytiikan mahdollisuuksista ja teknisestä toiminnasta.

Tuotososasta pyrin tekemään mahdollisimman helposti luettavan henkilölle, jolle asia on uusi. Tämän vuoksi käytin runsaasti kuvakaappauksia, koska mielestäni ne havainnollistavat käsiteltäviä asioita hyvin.

Suurin osa käyttämästäni aineistosta on verkkolähteitä. Verkkoanalytiikkaa ja Google Analyticsia käsitteleviä kirjoja on olemassa, mutta niiden sisältö on joiltain osin vanhentunutta. Koska Google päivittää jatkuvasti ohjelmistojaan, myös verkkoaineistot vanhentuvat nopeasti. Jotta työni pysyisi ajankohtaisena, yritin välttää oppaassa yksityiskohtia ja keskittyä toimintoihin, jotka todennäköisesti eivät poistu ohjelmistosta lähitulevaisuudessa.

Lähteet

Adobe 2015. Joka viides suomalainen estää nettimainokset. Tiedote 17.8.2015. Luettu 17.1.2016. <http://www.epressi.com/tiedotteet/mainonta/joka-viides-suomalainen-estaa-nettimainokset.html>

Berman, Ron 2015. Beyond the last touch: attribution in online advertising. 15.3.2015. Luettu 24.1.2016. <http://d1c25a6gwz7q5e.cloudfront.net/reports/2015-07-27-attribution.pdf>

Business Wire 2013. Abakus Launches 'Game-Changing Attribution' Solution to Measure the True Marginal Value of Marketing Campaigns. Artikkelit 17.6.2013. Luettu 17.1.2016.

Chaffey, Dave & Smith, PR 2013. Emarketing excellence – Planning and optimizing your digital marketing. 4th edition. Routledge Publishing, New York.

Davenport, Thomas & Harris, Jeanne 2007. Analysoi ja voita: kilpailun uusi tiede. Suomentanut Mari Paalosalo. Talentum 2007.

Google 2015. Sivuston nopeuden tulkinta. <https://support.google.com/analytics/answer/2383341?hl=fi>. Luettu 17.1.2016.

Hyvönen, Miikka 2015. Konversio-optimointi – Case Yritys X. Opinnäytetyö, Lahden ammattikorkeakoulu. Liiketalouden ala, markkinointi. Kevät 2015. https://publications.theseus.fi/bitstream/handle/10024/96624/Hyvonen_Miikka.pdf?sequence=1

IAB 2015. Ohjelmallisen ostamisen opas. IAB Finland ry Luettu 14.11.2015. <http://www.iab.fi/digimainonnan-abc/julkaisut-ja-opaat/ohjelmallisen-ostamisen-opas.html>

Kaushik, Avinash 2012. Dear Avinash: Attribution modeling, org culture, deeper analysis. Blogiteksti 13.8.2012. <http://www.kaushik.net/avinash/multi-channel-attribution-data-culture-analysis-faq/>. Luettu 7.12.2015.

Kaushik, Avinash 2010. Web Analytics 2.0 – The art of online accountability & science of customer centricity. Wiley Publishing, Indianapolis.

Kaushik, Avinash 2008. Excellent analytics tip #13: measure macro and micro conversions. Blogiteksti 26.3.2008. <http://www.kaushik.net/avinash/excellent-analytics-tip-13-measure-macro-and-micro-conversions/>. Luettu 15.11.2015.

Kaushik, Avinash 2007. Web Analytics – An Hour A Day. Wiley Publishing, Indianapolis.

Korpi, Janne 2013. Digitaalisen analytiikan attribuutiomallit ja monikanavamittaaminen. Teoksessa Häivälä, Janne & Pyyhtiä, Tomi (toim.) Digin Mitalla – Verkkomarkkinoinnin ja –myynnin mittaamisen käsikirja. Mainostajien liitto, Helsinki.

Leino, Antti 2013. Prosessikuvaus – Digitaalisen median suunnittelu ja palvelun tuotanto. Koulutusmateriaali. Huhtikuu 2013. GroupM Finland Oy, Helsinki.

MEC Global 2015. Spotlight on econometric modeling. December 2015.
<http://www.mecglobal.com/assets/publications/2015-12/Spotlight-On-Econometric-Modeling.pdf>. Luettu 19.1.2016.

Moore, Alex 2015. Eliminating bot traffic from Google Analytics once and for all. Blogiteksti 1.4.2015. <http://www.lunametrics.com/blog/2015/04/01/eliminating-bot-traffic-from-google-analytics-once-and-for-all/>. Luettu 17.1.2016.

Norman, Rob 2015. Ad blocking - be careful what you wish for. Blogiteksti 17.6.2015. https://www.linkedin.com/pulse/ad-blocking-careful-what-you-wish-rob-norman?trk=pulse_spock-articles. Luettu 17.1.2016.

Paavolainen, Sari 2015. Verkkoanalytiikka ja Google Analytics verkkoliiketoiminnan menestyksen mittareina. Insinööritö 15.4.2015. Metropolia Ammattikorkeakoulu, tietotekniikan koulutusohjelma.

Pyyhtiä, Tomi 2013. Mittaamisen työkalupakki. Teoksessa Häivälä, Janne & Pyyhtiä, Tomi (toim.) Digin mitalla – Verkkomarkkinoinnin ja -myynnin mittaamisen käsikirja. Mainostajien liitto, Helsinki.

Relander, Teemu 2013. Median oma analytiikka. Teoksessa Häivälä, Janne & Pyyhtiä, Tomi (toim.) Digin mitalla – Verkkomarkkinoinnin ja -myynnin mittaamisen käsikirja. Mainostajien liitto, Helsinki.

Roponen, Seppo 2013. Digitaalinen Markkinatutkimus. Teoksessa Häivälä, Janne & Pyyhtiä, Tomi (toim.) Digin mitalla – Verkkomarkkinoinnin ja -myynnin mittaamisen käsikirja. Mainostajien liitto, Helsinki.

Salo, Anna 2015. Tokkua digitaaliseen dataan (Mediatoimistot äänessä –blogi). Asiakkuusjohtaja, Dagmar. Blogiteksti 9.3.2015.
<http://blog.kauppalehti.fi/mediatoimistot-aaanessa/tolkkua-digitaaliseen-dataan>. Luettu 3.10.2015.

Shaw, Jason & Tsemekhman, Kiril 2014. Combating fraud in online advertising. Raportti, syyskuu 2014. http://integralads.com/wp-content/uploads/2014/10/IAS_Combating-Fraud-in-Online-Advertising_September-2014.pdf. Luettu 17.1.2016.

Tenkanen, Ismo 2013. Ansio konversiosta ostopolun eri vaiheille. Blogiteksti 25.6.2013. <http://www.iab.fi/iablogi/ansio-konversiosta-ostopolun-eri-vaiheille.html>. Luettu 7.11.2015.

Vastamäki, Raino 2013. Käytettävyytestit. Teoksessa Häivälä, Janne & Pyyhtiä, Tomi (toim.) Digin mitalla – Verkkomarkkinoinnin ja -myynnin mittaamisen käsikirja. Mainostajien liitto, Helsinki.

Zeifmal, Igal 2015. 2015 Bot traffic report: humans take back the web, bad bots not giving any ground. Raportti 9.12.2015. <https://www.incapsula.com/blog/bot-traffic-report-2015.html>. Luettu 17.1.2015.

Opas attribuutiomallinnuksen toteuttamiseen Google Analyticsilla



Google Analytics

Sisällys

1	Opas attribuutiomallinnuksen toteuttamiseen Google Analyticsilla	1
1.1	Attribuutiomallinnuksen tarpeen määrittely	1
1.2	Mittauksen suunnittelu	2
2	Tekninen toteutus	2
2.1	Analytiikka- ja mainonnanhallintajärjestelmien erot	3
2.2	Tiedon kerääminen sivustolta ja liikenteen lähteistä	4
2.2.1	Verkkosivuston tägitys	5
2.2.2	Liikenteen lähteiden tägitys	9
2.2.3	Tavoitteiden asettaminen Google Analyticsissa	12
3	Attribuutiomallinnus Google Analyticsilla	14
3.1	Konversiopolun tarkastelu monikanavaraporttien avulla	14
3.1.1	Yleiskatsaus	15
3.1.2	Avustetut konversiot	16
3.1.3	Suosituimmat konversioreitit	16
3.1.4	Viive	17
3.1.5	Reitin pituus	18
3.2	Sääntöihin perustuvat attribuutiomallit	19
3.2.1	Yksinkertaiset attribuutiomallit	21
3.2.2	Fragmentaariset attribuutiomallit	24
3.2.3	Mukautettu attribuutiomalli	26
3.3	Attribuutiomallien vertailu ja mallinnusprosessi	30
3.3.1	Marginaalinen analyysi	32
3.4	Esimerkki mallinnusprosessista	32
3.4.1	Lähtötilanne	32
3.4.2	Mallinnusprosessi	33
3.4.3	Lopputulos	35
	Lähteet	37

1 Opas attribuutiomallinnuksen toteuttamiseen Google Analyticsilla

Tämä opas esittelee vaiheittain attribuutiomallinnuksen toteutuksen Google Analyticsin maksuttoman version avulla. Opas on tarkoitettu digitaalisen mainonnan ja mediasuunnittelun parissa työskenteleville markkinoinnin ammattilaisille hahmottamaan mallinnuksen teknisen toiminnan ja prosessin pääpiirteet.

Huomioitavaa on, että Google päivittää analytiikkaohjelmistoaan jatkuvasti, joten esimerkiksi raporttien ulkonäkö ja sijainti ohjelmistossa saattavat muuttua. Tämän vuoksi olen koonnut oppaaseen työvaiheiden peruserätykset, ja suosittelen tarkastamaan päivitettyt tiedot ja yksityiskohdat Google Analyticsin ohjekeskuksesta (<https://support.google.com/analytics>).

1.1 Attribuutiomallinnuksen tarpeen määrittely

Ennen attribuutiomallinnuksen aloittamista tulisi pohtia, onko siihen tarvetta tai resursseja. Mallinnuksen toteuttamista voidaan pitää perusteltuna, jos:

- liiketoiminta on hyvin suoramarkkinointivetoista (direct response),
- mainospanostukset keskittyvät internetiin,
- ansio konversiosta on aiemmin jaettu ainoastaan yhden kosketuspisteen perusteella,
- käytettyjen kanavien rooli ostoprosessissa ei ole täysin tai ollenkaan selvillä,
- suurin osa verkkosivuston vierailijoista konvertoituu vasta usean vierailun jälkeen,
- on olemassa epäily siitä, ettei mediabudjetti tuota konversioita riittävän tehokkaasti määrällisesti tai laadullisesti tai riittävän nopeasti.

Sen sijaan attribuutiomallinnusta ei välttämättä kannata tehdä, jos:

- suurin osa verkkosivuston vierailijoista konvertoituu ensimmäisellä tai toisella käyntikerralla,
- suurin osa verkkosivuston vierailijoista konvertoituu yhden tai kahden päivän sisällä ensimmäisestä vierailusta,

- jos verkkosivuston suorituskyvyssä ja rakenteessa on suuria puutteita. Tällöin mediavalintojen optimointi on vielä toissijaista.

1.2 Mittauksen suunnittelu

Kun tarve attribuutiomallinnukselle on todettu, aloitetaan sen toteuttaminen mittauksen suunnittelulla. Web-analytiikka tuo lisäarvoa vain silloin, kun tiedetään mihin liiketoiminnallisiin kysymyksiin sillä haetaan vastauksia (Kaushik 2007, 79). Aluksi tulisi määritellä verkkosivuston olemassaolon tarkoitus, eli mitä liiketoiminnallista tavoitetta se ajaa ja mitä käyttäjän halutaan siellä tekevän (Kaushik 2007, 76).

Tämän jälkeen tehdään mittaussuunnitelma, jossa tunnistetaan ja määritellään pitkän aikavälin liiketoiminnalliset tavoitteet, toimenpiteet niihin pääsemiseksi, onnistumista mittaavat avainmittarit ja niiden tavoitetasot, sekä analytiikkatyökalusta tarkasteltavat tietojen osajoukot eli segmentit (Cutroni 2013). Suunnitelmassa tulisi myös määritellä verkkosivuston makro- ja mikrokonversiot (Google 2015i). Mittauksen suunnittelun jälkeen alkaa tekninen toteutus, jossa oma sivusto sekä kaikki käytettävät kanavat liitetään seurantaan.

2 Tekninen toteutus

Verkkomainonnan eri osa-alueiden, esimerkiksi bannerimainonnan, uutiskirjeiden, hakukonemainonnan ja sosiaalisen median tuloksia pitäisi pystyä seuraamaan vertailukelpoisesti yhdeltä raportilta (Salo 2015). Käytännössä tämä tarkoittaa sitä, että mainonnan seuranta rakennetaan keräämään dataa yhdelle ainoalle alustalle, joka voi olla esimerkiksi Google Analytics.

Jos taas hakusanamainonnan tuloksia seurataan omalla ostoalustallaan, display-mainontaa mainonnanhallintajärjestelmässä, verkkosivustoa analytiikkatyökalulla ja sosiaalisen median panostuksia omilla alustoillaan, on luotettavan kokonaiskuvan muodostaminen markkinointitoimenpiteiden toimivuudesta käytännössä mahdotonta. (Chaffey & Smith 2013, 113).

Prosessia, jossa seurantapisteet asetetaan sivustolle ja liikenteen lähteisiin, kutsutaan tagitykseksi. Kaikki mainonnassa käytettävät kanavat, kuten myös oma verkkosivusto, tulee tagittää, jolloin niistä kertyy dataa käytettävään analytiikka- tai mainonnanhallintajärjestelmään. Järjestelmässä asetetaan tavoitteet ja seurataan niihin pääsemistä sekä tuotetaan raportteja päätöksenteon tueksi.

Teknistä toteutusta suunniteltaessa on hyödyllistä arvioida verkkomainonnan ja -myynnin seurannan nykytila, jossa voi käyttää apuna esimerkiksi yksinkertaista tarkistuslistaa:

1. Onko käytössä kaikkien kanavien yhtenäinen seuranta?
Käytetäänkö seurannassa useampaa kuin yhtä analytiikka- tai mainonnanhallinta-alustaa?
Onko eri alustojen data yhdistettävissä ja päällekkäisyydet mahdollista rajata pois?
Kertyykö tieto, esimerkiksi klikkimäärät, samassa tahdissa eri alustoille?
2. Kuinka tagitys on toteutettu, ja onko datan kertyminen testattu ja todettu tarkaksi?
3. Kuinka konversiot luetaan eri kanavien ansioiksi?
Käytetäänkö mallina: viimeinen klikkaus, ensimmäinen klikkaus, näiden kahden välille painotettu vai jokin muu, mikä?
4. Otetaanko klikkaamattomat mainosnäytöt huomioon konversiopolun tarkastelussa?
5. Kuinka hyvin omaa myyntiprosessia ymmärretään?
Kuinka pitkä myyntiprosessi on ajallisesti?
Mikä verkon rooli on myyntiprosessissa?
6. Arvioidaanko liikenteen määrän lisäksi sen laatua?
Otetaanko mediavalinnoissa huomioon eri kanavien tuoman liikenteen CPA, CLV tai esimerkiksi keskiostoksen arvo?

(Mukaillen Chaffey & Smith 2013, 119)

2.1 Analytiikka- ja mainonnanhallintajärjestelmien erot

Attribuutiomallinnuksen suunnitteluvaiheessa kannattaa kiinnittää huomiota mittauksessa käytettävän ohjelmiston valintaan. Erityisesti kannattaa huomioida, että kaikki ohjelmistot eivät huomioi klikkaamattomia display-mainosnäyttöjä. Esimerkiksi

Google Analytics kerää tietoa ainostaan klikatuista mainosnäytöistä, jolloin suurinta osaa display-mainosnäytöistä ei oteta huomioon.

Klikkaamattomien mainosnäyttöjen sisällyttäminen analytiikkaan onnistuu ainoastaan mainonnanhallintajärjestelmien, kuten esimerkiksi DoubleClickin tai Adformin avulla (Chaffey & Smith 2013, 117). Doubleclick-datan syöttäminen automaattisesti Google Analyticsiin puolestaan onnistuu ainoastaan jos käytössä on maksullinen Google Analytics Premium. Mainosnäytöt voidaan tosin viedä jälkikäteen tarkasteltavaksi Google Analyticsin uusimpaan versioon, Universal Analyticsiin, manuaalisesti lataamalla CSV-tiedosto suoraan järjestelmään. Mainosnäyttöjä ei kuitenkaan pystytä tällöin yhdistämään konversion syntymiseen, jos mainosnäytön yhteydessä selaimeen ei ole asetettu evästettä.

Display-mainosnäytöt tulisi sisällyttää mittaukseen, sillä niiden merkitys kuluttajan huomion herättäjänä on suuri, ja ne vaikuttavat merkittävästi myöhemmin ostoprosessissa tehtyjen hakukonehakujen määrään (Adometry 2013). Display-mainontaan käyttäjä törmää viettäessään verkossa aikaa esimerkiksi keskustelupalstoilla ja uutissivustoilla, eikä välttämättä halua klikata banneria ja poistua sivulta. Näillä mainosnäytöillä saattaa olla suuri vaikutus ostopäätökseen myöhemmin, sillä ne toimivat huomion herättäjinä starter-roolissa. Mainostajien tulisi pyrkiä paremmin ymmärtämään display-mainonnan vaikuttavuutta ja roolia ostopolussa, sillä se on lisämyynnin kanava, jonka tuottamat konversiot jäisivät muuten saamatta. (Relander 2013, 102-105.)

Huomioitavaa kuitenkin on, että jos display-mainonnan rooli mediavalinnoissa on pieni tai olematon, mainonnanhallintajärjestelmän käyttöönotto yksinomaan attribuutiomallinnusta varten saattaa olla perusteetonta. Muita huomioitavia asioita alustan valinnassa ovat sen yhteensopivuus muiden järjestelmien kanssa, teknisen tuen saatavuus, prosessointinopeus, tekniikka jolla tietoa kerätään, helppokäyttöisyys ja kustannukset (Kaushik 2010, 21-30).

2.2 Tiedon kerääminen sivustolta ja liikenteen lähteistä

Jotta konversiopolusta voitaisiin muodostaa mahdollisimman totuudenmukainen käsitys, omalta sivustolta sekä sivustolle tulevan liikenteen lähteistä tulee kerätä tietoa. Tiedon

kerääminen sivustolta ja sivustolle tulevan liikenteen lähteistä poikkeavat toteutukseltaan. Verkkosivuston sisäinen tägitys eli sivustoseuranta on tärkeää, jotta käyttäjän toimintaa sivustolla voidaan mitata. Liikenteen lähteiden yksityiskohtainen seuranta on tärkeää, jotta päästäisiin selville eri lähteiden tuottaman liikenteen määrästä ja laadusta, ja konversiopolku voitaisiin mallintaa myöhemmin.

2.2.1 Verkkosivuston tägitys

Verkkosivuston sisäinen tägitys toteutetaan asentamalla käytettävän seurantatyökalun lyhyt koodinpätkä (tägi, scripti) pysyvästi verkkosivuston jokaisen sivun lähdekoodiin (Kaushik 2007, 113). Nämä koodit keräävät automaattisesti tietoa verkkosivustolta ja lähettävät sitä analytiikkaohjelmistoon etukäteen määriteltujen sääntöjen mukaisesti. Erilaisilla tägeillä mahdollistetaan muun muassa analytiikan seuranta, uudelleenmarkkinointi ja konversioseuranta (Jefimoff 2015).

Kun sivustolla käytetään useita tägejä (esim. Google Analytics, jonka lisäksi esim. Facebook-, Adwords-, ja mainonnanhallinnan tägit mainonnan uudelleenkohdennusta varten), on tägien asentaminen yksitellen jokaisen sivun lähdekoodiin aikaavievää, monimutkaista ja epäkäytännöllistä. Useat erikseen lisättävät tägit vaikeuttavat myös ongelmatilanteiden ratkaisemista, tägien hallinnan joustavuutta ja työllistävät sivua hallinnoivaa tahoa turhaan. (Google 2015a.)

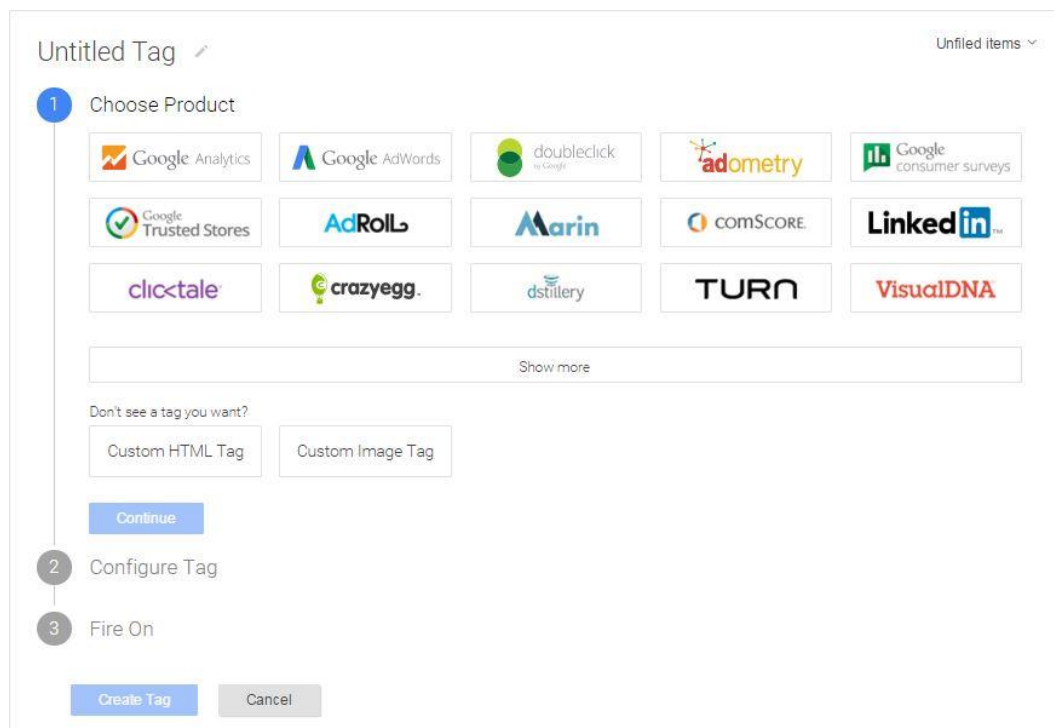
Kun käytössä on useita sivustolta tietoa kerääviä tägejä, vaivattomin tapa toteuttaa sivuston tägitys sekä tägien hallinta on käyttää ns. säilötägiä (container tag). Tällöin sivustolle asennetaan usean erillisen koodin sijasta jokaiselle sivulle ainoastaan yksi koodi, jonka sisälle voidaan vaivattomasti asentaa kaikki muut koodit erillisen käyttöliittymän kautta. (Google 2015a.) Yksi tämän hetken käytetyimmistä säilötägeistä on Google Tag Manager.

Google Tag Manager ”kuuntelee” käyttäjän toimintaa jokaisen vierailun aikana, mutta ei tallenna tietoja perusasetuksilla. Käyttöliittymässä luodaan erikseen jokaiselle tägille laukaisusäännöt (trigger). Laukaisusääntö määrittää, mikä käyttäjän suorittama toimenpide aktivoi koodin lähettämään tiedon kolmannelle osapuolelle, esimerkiksi Google Analyticsiin. Näin analytiikkaohjelmisto räätälöidään seuraamaan verkkosivustolla ainoastaan niitä asioita, jotka ovat relevantteja liiketoiminnan kannalta.

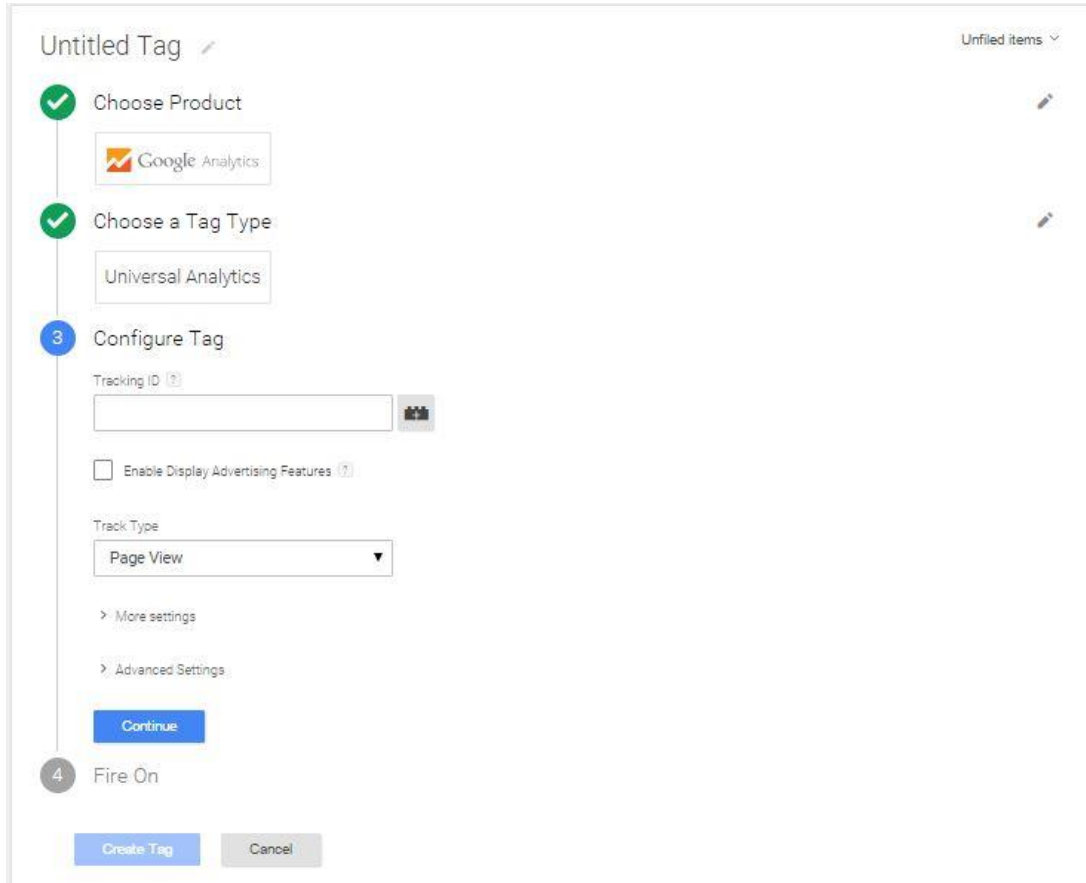
(Mertanen 2016.) Tägit voidaan myös asettaa laukeamaan jokaisella sivulatauksella, mutta useita eri tägejä käytettäessä tämä saattaa hidastaa sivustoa merkittävästi. (Google 2015a.) Google Tag Manager asennetaan luomalla palveluun uusi tili, jonka jälkeen tilin säilötägi sijoitetaan <body> -tunnisteen jälkeen oman sivuston lähdekoodiin.

Google Analyticsin tägin voi asentaa joko Google Tag Managerin avulla tai luomalla koodin Google Analyticsissa ja asentamalla sen suoraan sivun lähdekoodiin. Analyticsin asentaminen Google Tag Managerin avulla on helpoin vaihtoehto, sillä tägi siirtyy automaattisesti sivustolle tallentamisen jälkeen. Tägin luominen Google Tag Managerissa aloitetaan valitsemalla tuotteeksi Google Analytics. Tämän jälkeen määritetään onko luotava tägi uusi Universal Analytics -tägi vai perinteinen Google Analytics -tägi. (Google 2015k.)

Käytännössä tägin versioksi kannattaa aina valita Universal Analytics, sillä se on nopeampi ja tulee olemaan Googlen ainoa analytiikkatägi tulevaisuudessa. Tracking ID -kenttään syötetään oman Google Analytics tilin tunniste, joka löytyy Google Analyticsin järjestelmävalvojan (admin) asetuksista. Näin tiedot lähetetään Tag Managerista oikealle Google Analytics -tilille. (Mertanen 2016.)



Kuvio 1. Tägin luonti Google Tag Managerissa aloitetaan valitsemalla haluttu tuote yleisimmistä tägeistä.



The screenshot shows the 'Configure Tag' step in the Google Tag Manager interface. The title is 'Untitled Tag'. The progress bar indicates three steps: 'Choose Product' (completed), 'Choose a Tag Type' (completed), and 'Configure Tag' (current step). The 'Configure Tag' section includes a 'Tracking ID' field with a placeholder and a 'GA' icon, an unchecked checkbox for 'Enable Display Advertising Features', a 'Track Type' dropdown menu set to 'Page View', and links for 'More settings' and 'Advanced Settings'. A 'Continue' button is at the bottom of the configuration section. Below the configuration section is the 'Fire On' step, which is currently inactive. At the very bottom are 'Create Tag' and 'Cancel' buttons. In the top right corner, there is a link for 'Unfiled items'.

Kuvio 2. Google Analytics -tägiä luodessa valitaan sen tyyppi, asetukset ja laukaisusäännöt.

Tägillemme voidaan asettaa myös muita asetuksia, ja lopuksi asetetaan laukaisusääntö (fire on). Laukaisusääntö määrittää, milloin tägi aktivoituu ja lähettää tietoa Google Analyticsiin. Yleensä analytiikkatägi määritetään aktivoitumaan sivuston jokaisella sivulla.

Jos Google Tag Manageria ei haluta käyttää, tägin luominen onnistuu Google Analytics –tilin järjestelmänvalvoja (admin) –asetuksista. Tällöin luotu javascript-tägi tulee asentaa manuaalisesti verkkosivuston jokaisen sivun lähdekoodiin. (Google 2015j.)

```
<script>
(function(i,s,o,g,r,a,m){i['GoogleAnalyticsObject']=r;i[r]=i[r]||function(){
(i[r].q=i[r].q||[]).push(arguments)},i[r].l=1*new Date();a=s.createElement(o),
m=s.getElementsByTagName(o)[0];a.async=1;a.src=g;m.parentNode.insertBefore(a,m)
})(window,document,'script','/www.google-analytics.com/analytics.js','ga');

ga('create', 'UA-63685086-1', 'auto');
ga('send', 'pageview');

</script>
```

Kuvio 3. Google Analyticsissa luotu javascript-koodi, joka asennetaan verkkosivuston jokaisen sivun lähdekoodiin.

Jotta kertyvä tieto olisi luotettavaa, on tärkeää että tagit asennetaan sivustolle oikein. Onkin erittäin suositeltavaa, että asennusvaiheessa toimitaan yhdessä ohjelmiston toimittajan ja sivuston ylläpitäjän kanssa. (Kaushik 2007, 113.) Sivustolle väärin asennetut tagit voivat kerryttää dataa väärin analytiikkaohjelmistoon (Jefimoff 2015), mikä puolestaan voi johtaa väärin johtopäätöksiin ja liiketoiminnallisiin päätöksiin myöhemmin.

Jos käytössä on internetsivuston lisäksi mobiilisovellus, myös sieltä tulisi kerätä tietoa analytiikkaohjelmistoon. Verkkosivustolle lisättäviä javascript-seurantakoodeja ei sellaisenaan voida käyttää mobiilisovelluksissa, sillä eri alustoille (esimerkiksi Android, iOS, Windows Mobile) tehdyt sovellukset on ohjelmoitu eri ohjelmointikielillä, joissa javascript ei toimi. Tiedon keruu sovelluksesta onnistuu, kun käyttöön otetaan käytettävän analytiikkatoimittajan tarjoama Software Development Kit (SDK).

Kirjoitushetkellä Google Analytics voidaan liittää internet-selaimien lisäksi SDK:n avulla Android- ja iOS-sovelluksiin, Unity-pelimootorilla ohjelmoituihin peleihin sekä internetyhteydessä oleviin päätelaitteisiin (esimerkiksi kassajärjestelmä) Measurement Protocol –ominaisuuden avulla.

Overview



Kuvio 4. Reaaliaikaisen raportin yleiskatsaus –näkömä Google Analyticsissa kertoo, kuinka monta kävijää sivustolla on tarkasteluhetkellä.

Sivustoseurannan onnistumisen voi helposti tarkastaa reaaliaikaisen raportin avulla. Raportissa sivustolla tapahtuva toiminta näkyy muutaman sekunnin viiveellä, eli käytännössä reaaliajassa. Raportissa näkyy muun muassa sivustolla olevien käyttäjien määrä, päätelaite, selattavat sivut ja liikenteen lähteet. (Google 2015e.)

2.2.2 Liikenteen lähteiden tägitys

Mainosten ja muiden liikenteen lähteiden, esimerkiksi uutiskirjeiden ja sosiaalisen median päivitysten seuranta on helpointa toteuttaa yksilöimällä omalle sivustolle ohjaavat URL-osoitteet eri muuttujien avulla. Jos käytössä on Google Analytics, Google tarjoaa tähän tarkoitukseen maksuttoman työkalun. Työkalussa määritellään verkkosivuston URL-osoitteen lisäksi eri muuttujia, joiden ansiosta URL on yhdistettävissä tiettyyn mainokseen ja kanavaan. Tämä mahdollistaa kanavien tarkan vertailun myöhemmin kokonaisuutena kampanjoittain. (Chaffey & Smith 2013, 349.)

URL builder form

Step 1: Enter the URL of your website.

Website URL *

(e.g. <http://www.urchin.com/download.html>)

Step 2: Fill in the fields below. Campaign Source, Campaign Medium and Campaign Name should always be used.

Campaign Source *

(referrer: google, citysearch, newsletter4)

Campaign Medium *

(marketing medium: cpc, banner, email)

Campaign Term

(identify the paid keywords)

Campaign Content

(use to differentiate ads)

Campaign Name *

(product, promo code, or slogan)

GENERATE URL * Required field

Kuvio 5. Googlen URL-osoitteiden rakennustyökalu nopeuttaa URL-osoitteiden luontia kampanjoita varten.

Googlen URL-osoitteiden rakennustyökalussa osoitteeseen lisätään tietyt parametrit, jotka lähetetään Google Analytics-tilille kun osoitetta klikataan. Parametrit ovat verkkosivuston URL-osoite, liikenteen lähde, tulotapa, kampanjatermi sekä kampanjan sisältö ja nimi. (Google 2015f.)

Verkkosivuston URL-osoite on laskeutumissivu, johon eri kanavista ohjataan, esimerkiksi verkkosivuston etusivu. Tieto klikkauksesta lähetetään Google Analyticsiin tilille, joka käyttää samaa osoitetta. Liikenteen lähde (source) yksilöi sivuston nimen tai

verkkotunnuksen jossa kyseinen mainos näkyy, esimerkiksi Facebook. Tulotapa-kohtaan (medium) yksilöidään lähteen yleinen luokka, esimerkiksi sähköposti, internetviittaus tai maksullinen haku. Kampanjatermi-kohdassa (term) voidaan määrittää maksullisen haun avainsana. Sisältö-parametria (content) käytetään, kun samoissa kanavissa testataan eri mainosversioita tai toimintakehoitteita. Kampanjan nimi (campaign) tulisi olla yksilöllinen ja tunnistettava, esimerkiksi tarjouuskoodi, tuote tai ajankohta. Nimen tulisi olla sama jokaisessa samaan kampanjaan kuuluvassa liikenteen lähteessä, jotta kampanjaa voitaisiin tarkastella myöhemmin kokonaisuutena. (Google 2015g.)

Kanava	Kuvaus
Display	Interaktiot, joiden tulotapa on display tai cpm. Sisältää myös AdWords-interaktiot, joiden mainosten jakeluverkostoksi on asetettu content.
Paid Search	AdWordsin hakuverkostosta tai muista hakukoneista tuleva liikenne, jonka tulotapa on cpc tai ppc.
Other Advertising	Istunnot, joiden tulotavaksi on tagattu cpc, ppc, cpm, cpv, cpa, cpp, affiliate (ei kuitenkaan maksullinen haku).
Organic Search	Liikenne maksuttomasta hausta mistä tahansa hakukoneesta (eli joiden tulotapa on organic).
Social Network	Liikenne mistä tahansa noin 400 sosiaalisesta verkostosta (joita ei ole tagattu mainoksiksi).
Referral	Liikenne verkkosivustoista, jotka eivät ole sosiaalisia verkostoja.
Email	Istunnot, joiden tulotavaksi on tagattu email.
Direct	Istunnot, joissa käyttäjä kirjoitti verkkosivuston URL-osoitteen selaimeen tai tuli sivustolle kirjanmerkin kautta (eli lähde on (direct) ja tulotapa on (not set) tai (none)).

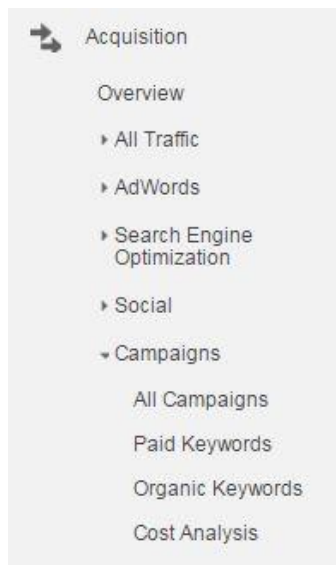
Kuvio 6. Monikanavaraporttien oletusarvoiset kanavatunnisteet (Google 2015k).

Parametreja lisätessä kannattaa huomioida, kuinka Google tunnistaa eri liikenteen lähteet osaksi attribuutiomallinnuksessa käytettäviä monikanavaraportteja (kuvio 6). Osa liikenteen lähteistä, kuten Googlen hakuverkosto ja yleisimmät sosiaaliset verkostot, tunnistetaan automaattisesti, kun taas esimerkiksi sähköpostisuorista tuleva liikenne tunnistetaan ainoastaan, jos sen tulotavaksi asetetaan URL-osoitteessa email. (Google 2015k.)

Jos esimerkiksi Facebookissa näytetään kahta eri mainosversiota osana samaa kampanjaa, toisen mainosversion yksilöity URL-osoite näyttäisi tältä:

http://www.esimerkki.fi/?utm_source=facebook&utm_medium=social&utm_content=linkkimainos-versio2&utm_campaign=joulukuu2015

Kampanja löydettäisiin Google Analyticsista nimellä joulukuu2015, ja kaikkia siihen kuuluvia kanavia voitaisiin tarkastella vertailukelpoisesti yhdeltä raportilta.



Kuvio 7. Kampanjoita, joissa on käytetty yksilöiviä muuttujia, voidaan tarkastella Google Analyticsissa valitsemalla kampanjat (campaigns) hankinta-valikosta (acquisition).

2.2.3 Tavoitteiden asettaminen Google Analyticsissa

Sivustolle asetettavia päämääriä kutsutaan Google Analyticsissa tavoitteiksi (goal). Kun sivustolla vieraileva käyttäjä suorittaa asetetun tavoitteen loppuun asti, tämä lasketaan yhdeksi konversioksi. Tavoitteina voidaan seurata sekä mikro- että makrokonversioita. Tavoitteita seuraamalla päästään selville siitä, selaavatko käyttäjät sivuston sisältöä odotusten mukaisesti, vai onko sivustolla tietty kohta jossa käyttäjiä poistuu ennen konversiota. (Google 2015i.) Huomioitavaa on, että tavoitteita ei seurata Google Analyticsin perusasetuksilla, vaan ne tulee määrittää erikseen (Mertanen 2016).

Tavoitetyyppi	Kuvaus	Esimerkki
Kohde	Tietyn paikan kuormat	<i>Kiitos rekisteröitymisestä!</i> Web-sivu tai sovellusnäyttö
Kesto	Istunnot, jotka kestävät vähintään määritetyn ajan	Tukisivustossa vietetty vähintään 10 minuuttia
Sivuja/näyttöjä istuntoa kohden	Käyttäjä katselee tietyn määrän sivuja tai näyttöjä	5 ladattua sivua tai näyttöä
Tapahtuma	Tapahtumaksi määritetty toiminto käynnistetään.	Some-suositus, videon toisto, mainosklikkaus

Kuvio 8. Tavoitteet löytyvät Google Analyticsissa conversions-valikon alta. (Google 2015i)

Tavoitteiksi voidaan asettaa tietylle sivulle päätyminen (esimerkiksi verkkokaupan kiitos-sivu), vierailun kesto, vierailun aikana selattujen sivujen määrä tai tietty tapahtuma, esimerkiksi painikkeen klikkaus (Google 2015i). Uusi tavoite luodaan Google Analyticsin järjestelmänvalvojan (admin) asetuksista. Tämän jälkeen Google Tag Managerissa luodaan uusi tägi ja laukaisusääntö, jonka toteutuessa Google Tag Manager lähettää tiedon onnistuneesta konversiosta Google Analyticsiin. (Mertanen 2016.)

Konversioiden määrän lisäksi myös niiden laatua tulisi pystyä seuraamaan, jotta verkkosivuston tuottavuutta liiketoiminnan näkökulmasta voitaisiin arvioida kokonaisuutena. Tätä varten jokaiselle mikro- ja makrokonversioille tulisi pystyä määrittämään jokin rahallinen arvo. (Kaushik 2011.)

Google Analyticsissa tavoitteen rahallinen arvo on helpointa määrittää, jos verkkosivuston makrokonversio on onnistunut myyntitapahtuma. Google Analytics tarjoaa verkkokauppoja varten luodun seurantakoodin, jonka avulla konversioiden arvot siirtyvät suoraan verkkokaupan ostoskorista verkkokauppa-raportteihin onnistuneen ostotapahtuman jälkeen.

Sen sijaan tavoitteen arvon määrittäminen on hankalampaa, jos verkkosivustolla ei ole suoraa ostomahdollisuutta, vaan sen tarkoituksena on esimerkiksi tuottaa liidejä organisaation myyntitiimille. Tässä tapauksessa makrokonversioksi voidaan valita sivustolta lähetettävä tarjouspyyntö, ja konversion keskimääräisen arvon voi arvioida

jakamalla tietyllä aikavälillä toteutuneiden kauppojen määrän verkkosivulta lähetettyjen tarjouspyyntöjen määrällä. (Google 2015i.)

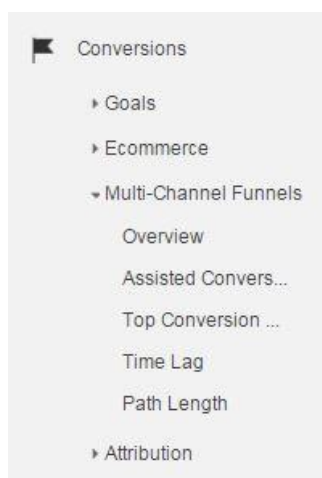
Molemmissa esimerkkitapauksissa konversion arvo tulisi tarkistaa uudestaan kuukausittain, jotta esimerkiksi myyntiprosessin kausiluontoiset vaihtelut sekä konversion arvon muutos pystyttäisiin tunnistamaan pitkällä aikavälillä. (Kaushik 2011)

Jotta mainontaan sijoitetun pääoman tuottoa voitaisiin seurata, tavoitteiden arvojen lisäksi kaikkien mainospanostusten hintatiedot tulisi tuoda Google Analyticsiin. Google-hakumainonnan hintatiedot siirtyvät automaattisesti, kun Adwords- ja Analytics-tilit yhdistetään. Sen sijaan muiden kuin Google-kampanjoiden hintatiedot voidaan lisätä lataamalla hintatiedoilla täytetty CSV-tiedosto suoraan Google Analyticsiin. (Google 2015i) Hintatietojen lisääminen voidaan myös automatisoida Google Analyticsin ohjelmointirajapinnan kautta, mutta tämä tapa vaatii edistyneitä ohjelmointitaitoja.

3 Attribuutiomallinnus Google Analyticsilla

3.1 Konversiopolun tarkastelu monikanavaraporttien avulla

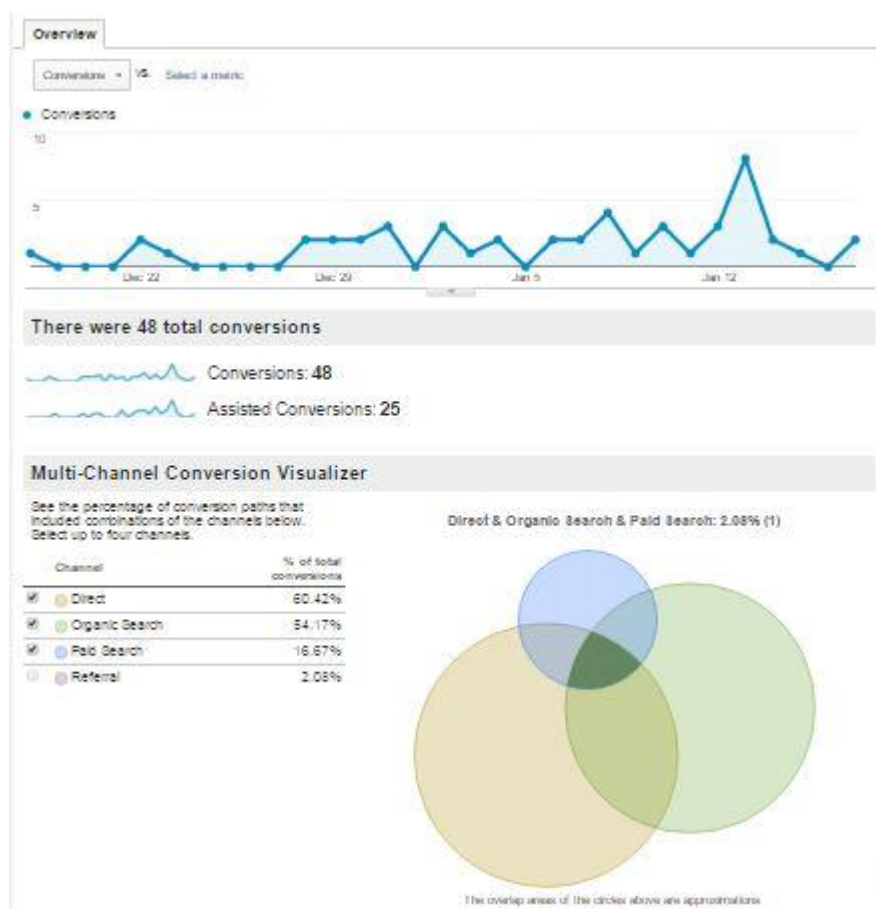
Konversiopolun analysointi aloitetaan tarkastelemalla Google Analyticsin monikanavaraportteja. Raportit ovat nimeltään yleiskatsaus (overview), avustetut konversiot (assisted conversions), suosituimmat konversioreitit (top conversion paths), viive (time lag) ja reitin pituus (path length). Monikanavaraportit löytyvät Google Analyticsista konversiot-valikon (conversions) alta.



Kuvio 9. Monikanavaraportit löytyvät Google Analyticsista konversiot-valikon (conversions) alta.

Nämä raportit auttavat hahmottamaan eri kanavien roolia konversiopolussa sekä polun pituutta ajallisesti ja kosketuspisteiden määrän suhteen, ja siten muodostamaan ison kuvan oman liiketoiminnan konversiosyklistä (Kaushik 2013). Raportit näyttävät myös kunkin kanavan tuottamien konversioiden arvon, jos tavoitteiden arvot on määritetty etukäteen niitä asetettaessa. Huomioitavaa on, että tieto ei kerro näihin raportteihin reaaliajassa, vaan parin päivän viiveellä (Google 2015m).

3.1.1 Yleiskatsaus



Kuvio 10. Monikanavaraporttien yleiskatsaus –raportti Google Analyticsissa.

Yleiskatsaus-raportti näyttää tietyllä ajanjaksolla toteutuneet konversiot sekä Venn-diagrammin, joka auttaa havainnollistamaan, kuinka moni konversiopolku sisälsi osan tai kaikki tarkasteluun valituista kanavista.

3.1.2 Avustetut konversiot

Avustetut konversiot –raportin avulla voidaan hahmottaa, toimiiko yksittäinen kanava paremmin huomion herättäjänä (starter), lähempänä konversiota olevana kosketuspisteenä (closer), vai niiden välillä (player). Raportissa näkyy, kuinka monta kertaa kukin kanava on ollut konversiopolun viimeinen kosketuspiste (Last click or Direct Conversions –sarake), kuinka monta kertaa kanava on ollut osana konversiopolkua, mutta ei viimeinen kosketuspiste (Assisted Conversions –sarake), sekä näiden kahden luvun suhde (Assisted/Last Click or Direct Conversions).

MCF Channel Grouping ?		Assisted Conversions	Assisted Conversion Value	Last Click or Direct Conversions	Last Click or Direct Conversion Value	Assisted / Last Click or Direct Conversions
1.	Direct	238 (26.53%)	—	186	—	1.28
2.	Referral	235 (26.20%)	—	305	—	0.77
3.	Organic Search	223 (24.86%)	—	4	—	55.75
4.	Paid Search	197 (21.96%)	—	9	—	21.89
5.	Social Network	3 (0.33%)	—	—	—	—
6.	(Other)	1 (0.11%)	—	—	—	—

Kuvio 11. Avustetut konversiot –raportti Google Analyticsissa. Tässä tapauksessa sivustoviittaukset ja suora liikenne ovat useimmin toimineet viimeisinä kosketuspisteinä, mutta orgaaniset hakutulokset ja hakusanamainonta ovat olleet mukana huomattavan monessa konversiopolussa.

Mitä suurempi tämä suhde on, sitä paremmin kanava on toiminut huomion herättäjänä myyntisuppilon alussa. Vastaavasti jos luku on lähellä nollaa, kanava on toiminut hyvin viimeisenä kosketuspisteenä juuri ennen konversiota. (Cutroni 2011.)

3.1.3 Suosituimmat konversioreitit

Suosituimmat konversioreitit –raportti näyttää kaikki yksilölliset konversioreitit, sekä kunkin reitin tuottaman konversioiden määrän. Huomioitavaa on, että raportti ei sellaisenaan kerro, mikä olisi optimaalisin tapa käyttää eri kanavia. Raportti kuitenkin antaa hyödyllistä tietoa kosketuspisteiden määrästä konversiopolussa, ja suodattamalla sen avulla voidaan myös löytää yksityiskohtia, esimerkiksi toimivimmat avainsanat. (Cutroni 2011.)

Primary Dimension: MCF Channel Grouping Path		Source/Medium Path	Source Path	Medium Path	Other	Channel Groupings
Secondary dimension						
MCF Channel Grouping Path						
						Conversions
1.	Organic Search	Referral				69 (14.56%)
2.	Paid Search	Referral				61 (12.87%)
3.	Direct	Referral				49 (10.34%)
4.	Organic Search	Referral	Direct			18 (3.80%)
5.	Paid Search	Referral	Direct			14 (2.95%)
6.	Direct	Referral	Direct			13 (2.74%)
7.	Paid Search	Direct	Referral			9 (1.90%)
8.	Paid Search × 2	Referral				6 (1.27%)
9.	Paid Search	Referral	Paid Search	Referral		4 (0.84%)
10.	Paid Search	Referral	Organic Search	Referral		4 (0.84%)

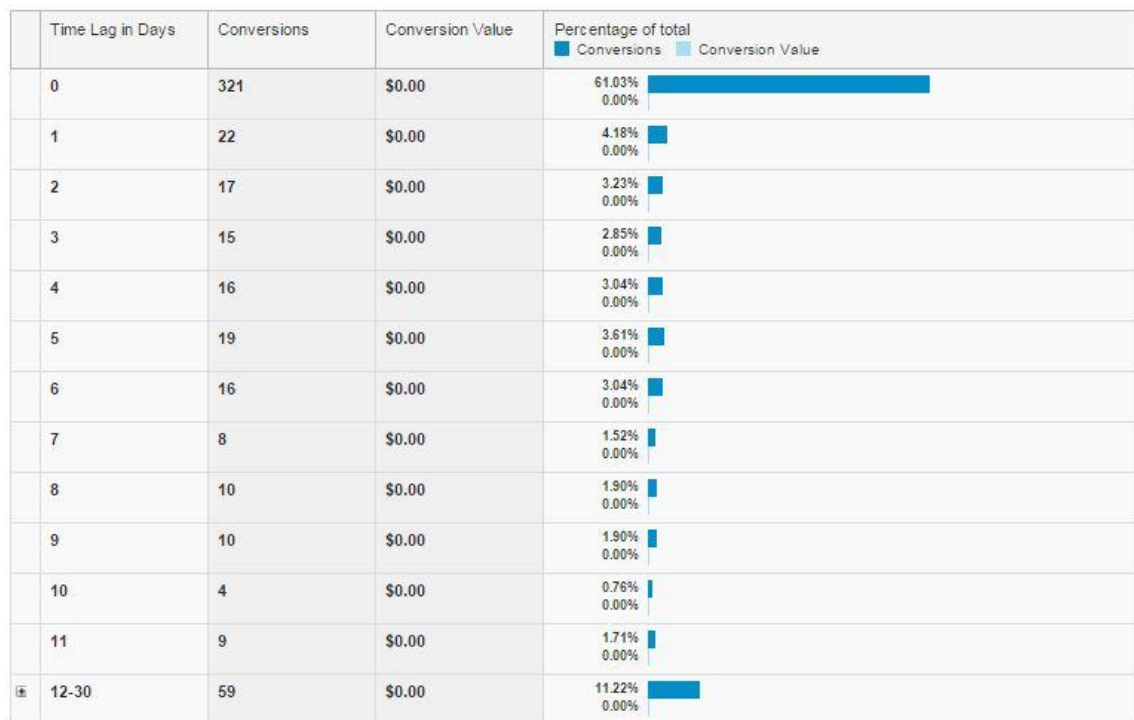
Kuvio 12. Suosituimmat konversioreitit –raportti Google Analyticsissa näyttää kaikki yksilölliset konversiopolut ja niiden kautta tulleiden konversioiden määrän tietyssä ajanjaksona.

Tämä raportti havainnollistaa hyvin, kuinka moni erilainen yhdistelmä kanavia voi johtaa konversioon. Koska asiakkaita ei voi pakottaa kulkemaan juuri tietynlaista konversiopolkua, tulisi mediabudjetin allokoinnissa löytää ”kultainen keskitie”. (Kaushik 2013.)

3.1.4 Viive

Viive-raportti antaa tietoa siitä, kuinka monta päivää kului konversiopolun ensimmäisestä kosketuspisteestä konversion syntymiseen. Raportti auttaa hahmottamaan oman liiketoiminnan konversiosyklin keskimääräisen keston. Tieto on tärkeä, kun omaa attribuutiomallia luotaessa valitaan analyysi-ikkunan kesto. Analyysi-ikkunan kesto on oletusarvoisesti 30 päivää, mutta jos esimerkiksi viive-raportin perusteella konversiosykli kestää 45 päivää, kannattaa ikkunan kesto säätää pidemmäksi, esimerkiksi 55 päivää. (Kaushik 2013.)

Mittauksessa ja tulosten analysoimisessa tulee huomioida, että konversioon johtavan polun pituus vaihtelee toimialoittain. Koska eri toimialoilla ostoprosessi on erilainen, yhtä oikeaa, yleispätevää attribuutiomallia ei ole olemassa. (Tenkanen 2013.) Esimerkiksi aika parturiin voidaan varata netistä päätyessä suoraan hakukoneesta varaussivulle, kun taas lomamatkan lentoja saatetaan vertailla monta viikkoa ennen ostopäätöstä. Konversiopolun pituus ajallisesti ja kosketuspisteiden määrässä määräytyy usein ostoprosessin pituuden perusteella.



Kuvio 13. Viive-raportti Google Analyticsissa.

3.1.5 Reitin pituus

Reitin pituus –raportti näyttää, kuinka monta konversiota syntyi, kun konversiopolussa oli 1,2,3,4,5,6,7,8,9,10,11 tai yli 12 kosketuspistettä (Google 2015h), ja se auttaa hahmottamaan konversiopolun pituutta kosketuspisteiden määrässä mitattuna. Raportti näyttää myös eripituisten konversiopolkujen tuottaman arvon, jos hintatiedot on tuotu Google Analyticsiin.

Path Length in Interactions	Conversions	Conversion Value	Percentage of total ■ Conversions ■ Conversion Value
1	29	\$0.00	5.75% 0.00%
2	189	\$0.00	37.50% 0.00%
3	90	\$0.00	17.86% 0.00%
4	56	\$0.00	11.11% 0.00%
5	32	\$0.00	6.35% 0.00%
6	34	\$0.00	6.75% 0.00%
7	13	\$0.00	2.58% 0.00%
8	8	\$0.00	1.59% 0.00%
9	14	\$0.00	2.78% 0.00%
10	11	\$0.00	2.18% 0.00%
11	7	\$0.00	1.39% 0.00%
12+	21	\$0.00	4.17% 0.00%

Kuvio 14. Reitin pituus –raportti Google Analyticsissa osoittaa, että tässä tapauksessa konversiopolussa on useimmiten vain muutama kosketuspiste ennen konversiota.

3.2 Sääntöihin perustuvat attribuutiomallit

Tässä luvussa esittelen vakiintuneet, sääntöihin perustuvat attribuutiomallit, jotka löytyvät valmiina Google Analyticsin maksuttomasta versiosta. Perustelen myös, miksi valmiiden mallien käytössä tulisi noudattaa varovaisuutta, ja käyn läpi mukautetun attribuutiomallin rakentamisen perusteet ja haasteet.

Käytän havainnollistavana esimerkkinä kuvitteellista konversiopolkua, jonka perusteella konversioita on tullut eniten.



Kuvio 15. Kuvitteellinen, eniten konversioita tuottanut konversiopolku.

Tässä polussa bannerimainos on herättänyt ensimmäisenä käyttäjän huomion. Tämän jälkeen käyttäjä on klikannut linkkiä sosiaalisessa mediassa, tehnyt haun hakukoneessa ja päätenyt sivustolle klikattuaan maksettua hakumainosta. Vierailtuaan sivustolla, mutta konvertoitumatta, käyttäjälle on uudelleenkohdennettu mainontaa, jonka jälkeen tämä on tullut sivulle suoraan kirjoittamalla url-osoitteen osoitekenttään ja konvertoitunut.


Konversio voidaan lukea näiden viiden kanavan ansioksi eri tavoin, riippuen siitä minkä attribuutiomallin avulla polkua tarkastellaan. Näiden mallien avulla kunkin kanavan roolista konversiopolussa voidaan tehdä oletus, jonka perusteella mediabudjetin allokointiin tehdään muutoksia tavoitteiden saavuttamiseksi. Prosessi toistetaan säännöllisin väliajoin, jolloin arvioidaan käytetyn mallin toimivuus ja muodostetaan uusi hypoteesi. Käyn läpi esimerkin tällaisesta prosessista luvussa 3.4.

Eri attribuutiomallit voidaan luokitella yksinkertaisiin ja fragmentaarisiin malleihin. Yksinkertaisia ovat viimeinen klikkaus, viimeinen epäsuora klikkaus, viimeinen hakumainoksen klikkaus- ja ensimmäinen klikkaus, ja ne lukevat konversion ainoastaan yhden kosketuspisteen ansioksi. Fragmentaariset mallit jakavat konversion useamman kanavan ansioksi, ja niistä yleisimmin käytetyiksi ovat vakiintuneet lineaarinen, vaimenemisaika- sekä sijaintipohjainen malli.

Yksinkertaisten ja fragmentaaristen attribuutiomallien rinnalle on kehitetty ns. algoritmisen attribuution menetelmä. (Adometry 2012.) Menetelmä eroaa perinteisestä attribuutiomallinnuksesta siten, että huomioon otetaan myös ne konversiopolut, jotka eivät johtaneet konversioon. Algoritmisen attribuutio on mahdollista Google Analyticsissa vain, jos käytössä on maksullinen Premium-versio.

3.2.1 Yksinkertaiset attribuutiomallit

Viimeinen klikkaus (last interaction)




Kuvio 16. Viimeisen klikkauksen malli lukee konversion arvon kokonaan viimeisen kosketuspisteen ansioksi.

Tämä attribuutiomalli lukee konversion konversiopolun viimeisen kanavan ansioksi, ja se on yleisin mainostajien käyttämä malli. Malli on useimmissa tapauksissa ongelmallinen, sillä se ei huomioi käyttäjän aiemmin kohtaamia mainosviestejä. (Chaffey & Smith 2013, 113.) Esimerkissä konversio olisi tämän mallin perusteella kokonaan suoran liikenteen ansiota. Aikaisempien kosketuspisteiden huomiotta jättäminen ja niihin panostamisen vähentäminen olisi kuitenkin todennäköisesti virheellinen johtopäätös, koska ilman muiden kanavien vaikutusta käyttäjä tuskin olisi tullut suoraan sivulle ja konvertoitunut.

Viimeistä klikkausta arvottava malli saattaa kuitenkin toimia, jos myyntitapahtumat eivät sisällä harkintavaihetta juuri lainkaan vaan kiinnostus on tarkoitus herättää ostohetkellä (Google 2015c). Lisäksi malli auttaa hahmottamaan, mitkä kanavat toimivat parhaiten juuri ennen konversiota.


Viimeinen epäsuora klikkaus (last non-direct click)



Kuvio 17. Viimeisen epäsuoran klikkauksen malli suodattaa pois suoran liikenteen, ja lukee konversion kokonaan sitä edeltäneen kosketuspisteen ansioksi.

Tämä malli jättää suoran liikenteen huomiotta ja arvottaa konversion kokonaan viimeiselle kanavalle, jota käyttäjä klikkasi ennen konversiota (Google 2015b). Käytännössä malli on siis sama kuin viimeisen klikkauksen malli; ainoastaan suora liikenne suodatetaan pois (Google 2015c). Esimerkissä konversio olisi tämän mallin mukaan kokonaan uudelleenkohdennusmainonnan ansiota. Tämä on kuitenkin virheellinen tulkinta, sillä uudelleenkohdennusta ei olisi voitu tehdä, ellei käyttäjä olisi vierailut sivustolla aiempien kosketuspisteiden ansiosta.


Viimeinen hakumainoksen klikkaus (last Adwords-click)



Kuvio 18. Viimeisen hakumainoksen klikkaus –malli lukee konversion kokonaan hakumainonnan ansioksi.

Tämä malli arvottaa eniten viimeistä klikattua hakukonemainosta (Google 2015b), ja soveltuu siksi vain hakumainonnan roolin hahmottamiseen konversiopolussa.

Ensimmäinen klikkaus (first click)




Kuvio 19. Ensimmäisen klikkauksen malli lukee konversion kokonaan konversiopolun ensimmäisen kosketuspisteen ansioksi.

Viimeistä klikkausta eniten arvottavan mallin vastakohta, joka lukee konversiot kokonaan polun ensimmäisen kosketuspisteen ansioksi (Google 2015b). Koska tämäkin malli huomioi ainoastaan yhden kosketuspisteen kustakin konversiopolusta, on budjetin allokointi mallin perusteella erittäin vaikeaa.

Jos konversiopolku sisälsi useamman kuin yhden kosketuspisteen, ei käyttäjä selvästikään konvertoitunut heti. Tällöin konversion arvon lukeminen ainoastaan ensimmäisen kanavan ansioksi on täysin perusteetonta. (Kaushik 2013.)

3.2.2 Fragmentaariset attribuutiomallit

Lineaarinen (linear)




Kuvio 20. Lineaarinen attribuutiomalli arvottaa jokaista käytettyä kanavaa tasaisesti.

Lineaarinen attribuutiomalli jakaa konversion tasaisesti kaikkien kosketuspisteiden ansioksi (Google 2015b), ja sitä kannattaa käyttää, kun kampanjan tavoite on tietoisuuden ylläpitäminen tai jatkuva yhteydenpito asiakkaaseen (Google 2015c).

Tämä malli on parempi kuin yksinkertaiset mallit, koska kaikki kosketuspisteet arvotetaan tasaisesti. Useimmissa tapauksissa tämäkään malli ei kuitenkaan kuvaa tilannetta kovin hyvin, sillä todellisuudessa eri kanavat hyvin harvoin vaikuttavat täsmälleen saman verran konversion syntymiseen. (Kaushik 2013.)

Vaimenemisaika (time decay)




Kuvio 21. Vaimenemisaika –malli arvottaa kaikkia kanavia, mutta antaa kanavalle sitä enemmän arvoa, mitä lähempänä se on ollut konversiota ajallisesti.

Tämä attribuutiomalli antaa eniten arvoa viimeiselle kosketuspisteelle, toiseksi eniten toiseksi viimeiselle, ja vähiten ensimmäiselle kosketuspisteelle. Konversiota ajallisesti lähimpänä olevat kosketuspisteet saavat siis eniten arvoa. (Google 2015b.)

Kosketuspisteiden prosentuaalinen arvo määräytyy puoliintumisajan perusteella, joka on oletuksena 7 päivää. Konversiota edeltäneen seitsemän päivän aikana tapahtunut kontaktipiste saa puolet siitä arvosta, jonka konversiopäivänä tapahtunut kontaktipiste saa. 14 päivää ennen konversiota tapahtunut kontaktipiste saa 1/4, 21 päivää ennen konversiota ollut konversiopiste 1/8 konversiopäivän kontaktipisteen arvosta ja niin edelleen. (Google 2015c.) Puoliintumisajan voi itse määrittää.

Tämä malli on jo toimivampi kuin aiemmin esiteltyt, sillä se jakaa arvon jokaisen kosketuspisteen ansioksi tiettyjen sääntöjen perusteella. Tämä malli toimii hyvin vertailukohtana, kun omaan liiketoimintaan mukautettua attribuutiomallia halutaan vertailla jonkin muun mallin kanssa. (Kaushik 2013.)

Sijaintipohjainen (position based)



Kuvio 22. Sijaintipohjainen malli arvottaa eniten ensimmäistä ja viimeistä kosketuspistettä, ja jakaa jäljellejäävän arvon tasaisesti muille kosketuspisteille.

Sijaintipohjainen malli lukee konversion 40-prosenttisesti sekä ensimmäisen että viimeisen kosketuspisteen ansioksi, ja jakaa loput 20% tasaisesti niiden välissä olleille kosketuspisteille (Google 2015b). Malli siis arvottaa eniten kanavaa joka herätti kuluttajan huomion ja aloitti konversiopolun, sekä kanavaa joka onnistui toimimaan closerina ennen konversiota.

Esimerkissä 40% luettaisiin sekä display-bannerin että suoran liikenteen ansioksi, ja sosiaalinen media, hakukonemainonta ja uudelleenkohdennus saisivat kukin 6,7% konversion arvosta.

Malli toimii hyvänä pohjana, kun aletaan tehdä omaa liiketoimintaan ja toimialaan mukautettua attribuutiomallia (Kaushik 2013).

3.2.3 Mukautettu attribuutiomalli


Sääntöihin perustuvat attribuutiomallit ovat monessa tapauksessa ongelmallisia, koska useimmiten ne soveltuvat ainoastaan marginaalitapauksiin. Tämän vuoksi attribuutiomallinnuksesta saadaan suurin hyöty, kun omaa liiketoimintaa kuvaamaan luodaan mukautettuja attribuutiomalleja liiketoiminnan ominaispiirteiden perusteella. Näistä piirteistä päästään selville tarkastelemalla aiemmin kuvattuja monikanavaraportteja, haastatteleamalla yrityksen päättäjiä sekä analysoimalla aiemmin

tehtyjä mediavalintoja ja niillä saavutettuja tuloksia. Kun mukautettua mallia tehdään Google Analyticsissa, lähtökohtana käytetään jotain edelläkuvatuista sääntöihin perustuvista malleista. Pohjaksi tulisi valita sellainen malli, jonka uskotaan olevan lähimpänä oman liiketoiminnan mediapanostusten optimaalisinta budjettijakoa. Usein parhaana lähtökohtana toimii sijaintipohjainen malli. (Kaushik 2013.)

Model Name

Uusi mukautettu malli

Baseline Model

 **Position Based**

Specify the amount of conversion credit based on the position.

First interaction: %

Middle interactions: % *This will be distributed evenly to all middle interactions.*

Last interaction: %

Total: **100 %** *Must be 100%*

Kuvio 23. Mukautetun mallin pohjana käytetään sääntöihin perustuvia malleja. Tässä tapauksessa pohjaksi on valittu sijaintipohjainen malli, jonka painotukset voidaan säätää.

Jos mukautetun mallin pohjana käytetään sijaintipohjaista mallia, voidaan kosketuspisteiden prosentuaalista painotusta muuttaa. Tämän jälkeen säädetään analyysi-ikkunaa, joka määrittää, kuinka pitkältä ajalta kosketuspisteet huomioidaan konversion syntymisessä. Sopiva analyysi-ikkuna löytyy, kun viive-raportista selvitetään konversiosyklin kesto, ja lisätään siihen varmuuden vuoksi lisää aikaa. Jos esimerkiksi viive-raportin perusteella konversiosykli kestää noin 35 päivää, kannattaa analyysi-ikkunan kestoksi määrittää 45 päivää. (Kaushik 2013.)



Kuvio 24. Mukautetussa attribuutiomallissa analyysi-ikkunan keston voi säätää välille 0-90 päivää.

Konversiopolkuja ja kosketuspisteitä voidaan arvottaa sen mukaan, kuinka kauan niiden sivustolle tuomat käyttäjät viettävät aikaa sivulla, tai sen mukaan, kuinka monella sivuston sivulla käyttäjä käy vierailun aikana. Esimerkiksi verkkokauppa saattaa arvottaa enemmän kosketuspisteitä jotka tuottavat sivuja selanneita käyttäjiä, kun taas pitkiä artikkeleita tarjoava sivusto käyttäjiä jotka ovat viettäneet sivustolla paljon aikaa. Tällä asetuksella mahdollistetaan kanavien tarkempi arvottaminen käyttäjän toiminnan perusteella, vaikka konversiopolku olisi ollut täsmälleen samanlainen.



Kuvio 25. Mukautetun mallin voi asettaa painottamaan kosketuspisteitä sivustolla vietetyn ajan tai käyttäjän sitoutumisen perusteella.

Lopuksi mukautettuun attribuutiomalliin voidaan lisätä sääntöjä, joiden perusteella konversion arvo jaetaan vielä tarkemmin eri kosketuspisteille. Esimerkiksi kanaville, jotka tuottavat välittömän poistumisen sivulta, voidaan antaa vähemmän arvoa. Tai jos kampanjan tavoitteena on ainoastaan ohjata sivustolle, voidaan säännöksi asettaa klikkauksien arvottaminen pelkkiä mainosnäyttöjä enemmän. Tämä sääntö auttaa jakamaan konversion arvon tarkemmin kuin pelkkä kosketuspisteen sijainti konversiopolussa.

Apply custom credit rules On

Remove

Include-
Ad Format
Exactly matching
HTML

or

Add 'OR' statement

and

Remove

Include-
Visit Duration (Seconds)
Greater than
60

or

Add 'OR' statement

and

Add 'AND' statement

credit 1.5 times other interactions in the conversion path

Kuvio 26. Mukautettuun malliin voidaan lisätä hyvin tarkkoja painotussääntöjä.

Sääntöjä lisätessä tulisi hyvin tarkasti pohtia oman liiketoiminnan ominaispiirteitä. On tärkeää ensin päästä selville siitä, minkälaista käyttäjän toimintaa arvostetaan eniten, minkälainen toiminta ja käyttäytyminen tuo eniten arvoa liiketoiminnalle, ja arvostetaanko tiettyjä kanavia, kampanjoita tai mainosversioita jo oletusarvoisesti enemmän.

Mukautettua mallia rakentaessa tulee myös huomioida, mitä konversiota sen avulla halutaan tarkastella. Esimerkiksi verkkokaupassa ostotapahtuma ja rekisteröityminen voivat molemmat olla konversioita, mutta niihin johtavat konversiopolut hyvin erilaisia. Ensimmäisiä mukautettuja malleja tehtäessä sääntöjä ei kannata lisätä liikaa päällekkäin, ja niiden arvotukset kannattaa säätää melko pieniksi.

Mukautetun mallin heikkoudet eivät niinkään liity analytiikkaohjelmiston teknisiin ominaisuuksiin tai rajoitteisiin, vaan mallin tekijän kykyyn huomioida olennaiset asiat ja sisällyttää ne onnistuneesti luotuun malliin (Kaushik 2010, 364).

3.3 Attribuutiomallien vertailu ja mallinnusprosessi

Mukautetun mallin luomisen jälkeen sitä vertaillaan muihin malleihin, jotta mediabudjetin allokoinnista voitaisiin tehdä suosituksia. Google Analyticsissa on mallinvertailutyökalu, jonka avulla voi vertailla yhtä aikaa kolmea eri mallia samassa näkymässä. Havainnollistan mallinvertailutyökalun käyttöä esimerkillä, jossa mukautettua attribuutiomallia verrataan vaimenemisaika-malliin.

Create or edit attribution model

Model Name
Mukautettu v1

Baseline Model
Position Based

Specify the amount of conversion credit based on the position.

First Interaction: 10 %
Middle Interactions: 50 % *This will be distributed evenly to all middle interactions.*
Last Interaction: 40 %

Total: 100 % *Must be 100%*

Lookback Window
Set: 14 days prior to conversion

Adjust credit based on user engagement
Distribute credit proportionally based on: time on site

Apply custom credit rules

Include: Visit Duration (seconds) Greater than: 60

or

Add "OR" statement

and

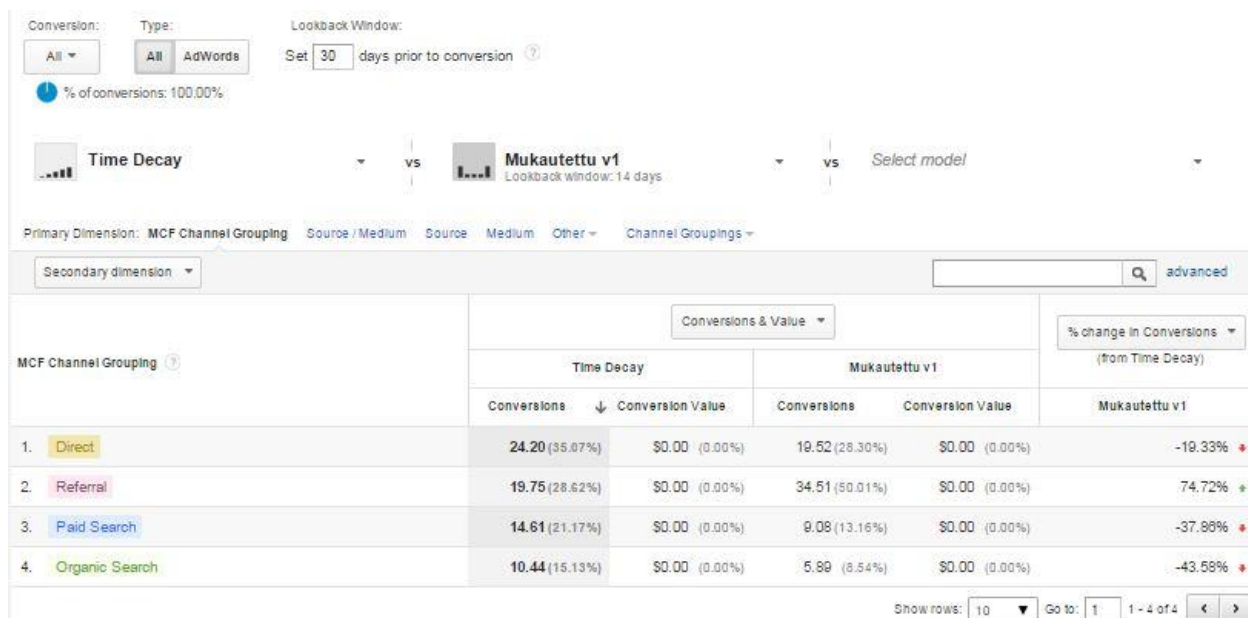
Add "AND" statement

credit: 1.2 times other interactions in the conversion path

Kuvio 27. Mukautettua attribuutiomallia luotaessa valitaan pohjaksi valmis malli, johon lisätään asetukset ja säännöt.

Tässä mukautetussa mallissa on käytetty pohjana sijaintipohjaista mallia. Ensimmäiselle kosketuspisteelle arvotetaan 10%, viimeiselle 40% ja niiden välissä oleville 50%. Analyysi-ikkunan kestoksi on asetettu 14 päivää, ja sivustolla enemmän aikaa viettäviä käyttäjiä tuottaneita kanavia arvotetaan enemmän. Lisäksi on luotu sääntö, jonka

perusteella kanava saa 1.2 kertaisten arvon, kun sen tuoma käyttäjä viettää sivustolla yli 60 sekuntia.



Kuvio 28. Google Analyticsin mallinvertailutyökalussa voi vertailla kolmea attribuutiomallia samanaikaisesti.

Malleja vertaillessa huomataan, että ne arvottavat konversiot täysin eri tavalla. Vaimenemisaika-mallin mukaan suora liikenne saa eniten konversion arvosta (35,07%), sivustoviittaukset toiseksi eniten (28,62%), maksettu haku kolmanneksi eniten (21,17%) ja orgaaniset hakutulokset vähiten (15,13%) konversion arvosta. Mukautettu malli puolestaan antaa vähemmän arvoa suoralle liikenteelle (28,30%), maksetulle (13,16%) ja orgaaniselle haulle (8,54%), mutta selvästi enemmän sivustoviittauksille (50,01%).

Viimeinen sarake (% change in conversions) kertoo prosentuaalisen muutoksen eri kanavien arvotuksessa eri mallien välillä, ja sitä voi käyttää suuntaa-antavana tietona budjetin allokoinnissa.

Tämän yksittäisen vertailun perusteella mediabudjettia voitaisiin vähentää maksetusta hausta, ja vastaavasti lisätä sivustoviittauksiin menevän budjetin osuutta. Lisäämällä suodattimia raporttiin päästäisiin vielä yksityiskohtaisemmin selville siitä, mihin sivustoviittauksiin tulisi panostaa eniten.

Tietyn ajan, esimerkiksi kuukauden päästä, malleja tulisi jälleen vertailla uudestaan, havaita muutokset konversioissa, ja tehdä raportin perusteella uusi hypoteesi ja suositukset budjettijaosta. Ainoastaan tällaisella syklisellä lähestymistavalla attribuutiomallinnuksesta saadaan pitkällä aikavälillä hyötyä (Kaushik 2012).

Tärkeää on tässä vaiheessa ymmärtää, että mikään malli ei ole täydellinen, vaan omaa mallia tulisi jatkuvasti kehittää ja vertailla aikaisempiin. Suositeltavaa olisi myös testata useampaa mukautettua mallia samaan aikaan systemaattisesti. (Adroll 2015.)

3.3.1 Marginaalinen analyysi

Marginaalinen analyysi on vaihtoehtoinen menetelmä attribuutiomallien vertailulle, ja sillä testataan systemaattisesti erilaisia vaihtoehtoja optimoida mediabudjetin käyttö. Perusidea on ottaa kokonaisbudjetista tietty osa, ja lisätä se yksittäiseen kanavaan. Tämän jälkeen seurataan konversioiden määrää ja laatua tietyllä aikavälillä, ja testi toistetaan.

Jos esimerkiksi budjetti jakautuu tasaisesti kolmelle kanavalle, jotka ovat display, hakusanamainonta ja Facebook-mainonta, valitaan näistä kanavista yksi, jonka budjettia aletaan kasvattamaan. Konversioiden määrää seurataan, ja tapahtunut muutos luetaan tehdyn budjettimuutoksen ansioksi. Yksittäisen kanavan budjettia kasvatetaan, kunnes budjetin muutoksella ei ole enää vaikutusta konversioihin. Tämän jälkeen testataan samalla menetelmällä jotain muuta kanavaa. (Kaushik 2010, 367.)

Tämän lähestymistavan ongelmana on vaikeus poissulkea kaikki tekijät, jotka vaikuttavat testien lopputulokseen. Lisäksi yhden kanavan testaaminen kerrallaan vie huomattavasti aikaa, varsinkin jos kanavia on käytössä paljon. (Kaushik 2010, 368.)

3.4 Esimerkki mallinnusprosessista

3.4.1 Lähtötilanne

Autojälleenmyyjän sivuston tarkoituksena on tuottaa koeajovarauksia ja tarjota informaatiota asiakkaalle. Kauppias haluaa kasvattaa myyntiä ja liikevoittoa. Yrityksellä on jo käytössä onnistuneesti implementoitu web-analytiikka, ja verkkosivusto on

optimoitu suorittamaan tavoitteita kohti mahdollisimman hyvin. Seuraavana keinona koeajovarausten määrän, myynnin ja liikevoiton kasvattamiseksi päätetään tutkia mediavalintoja tekemällä attribuutiomallinnusta.

Kauppiaan markkinointibudjetti on 8 000 €/kk, jolla tehdään jatkuvana kampanjana display- ja hakusanamainontaa.

Taulukko 1. Autokauppiaan mainosbudjetin jakautuminen.

Kanava	Kuukausibudjetti
Display	2 000 €
Hakusanamainonta	6 000 €
Yhteensä	8 000 €

Ansio konversioista on aikaisemmin annettu vain viimeisen kosketuspisteen perusteella, minkä vuoksi hakusanamainonnan budjetti on suurempi kuin displayn. Hakusanamainonnan budjetin jatkuva kasvatus ei kuitenkaan ole tuottanut merkittävästi lisää konversioita.

Koeajovaroja tulee lähtötilanteessa kuukaudessa keskimäärin 30. Myyntitiimi onnistuu myymään keskimäärin 25 000 € -hintaisten auton 30%:lle koeajon varanneista, myyntikatteen ollessa keskimäärin 9 %.

3.4.2 Mallinnusprosessi

Kauppiaan markkinointitiimi laatii ensin mittaussuunnitelman.

Taulukko 2. Esimerkki mittaussuunnitelmasta.

Liiketoiminnallinen tavoite	Myyntin kasvatus
Keino jolla tavoitteeseen päästään	Koeajovarausten määrän kasvatus
Verkkosivuston makrokonversio	Koeajovaraus
Verkkosivuston mikrokonversiot	Uutiskirjeen tilaus, hinnaston lataus
Seurattavat KPI:t	Koeajovarausten määrä, konversioaste, konversion hinta (CPA)s
Tavoitetasot	Koeajovaroja/kk>40
Tietojen osajoukot eli segmentit	Liikenteen lähteet

Tämän jälkeen kampanjaa varten luodaan muokatut URL-osoitteet, jotka otetaan käyttöön kaikissa kanavissa.

Mallinnusprosessi aloitetaan tutkimalla monikanavaraportteja käsityksen muodostamiseksi konversiosyklistä. Viimeisen 12 kuukauden aikana on tullut 363 koeajovarausta, ja avustetut konversiot -raportista selviää karkeasti eri kanavien rooli toteutuneissa konversioissa.

Taulukko 3. Esimerkki Google Analyticsin avustetut konversiot -raportista.

Kanava	Last click or direct conversions	Assisted Conversions	Assisted/Last Click or Direct Conversions
Maksettu haku	181 (50.14%)	72 (19.62%)	0.40
Orgaaninen haku	137 (37.95%)	113 (30.79%)	0.82
Display	26 (7.20%)	96 (26.16%)	3.69
Suora liikenne	17 (4.71%)	85 (23.16%)	5.00

Raportista havaitaan, että hakusanamainonta ja orgaaniset hakutulokset olivat melkein 90% konversioista viimeinen kosketuspiste, ja toimivat myös taulukon lukujen perusteella hyvin closerina lähellä konversiota. Display-mainonta ja suora liikenne sen sijaan eivät tuottaneet juurikaan suoria konversioita, mutta ne olivat mukana huomattavan monessa konversiopolussa ennen viimeistä kosketuspistettä.

Viive-raportti osoittaa konversiosyklin kestävän keskimäärin 20 päivää, ja reitin pituus -raportti konversiopolussa olevan useimmissa tapauksissa 6-7 kosketuspistettä.

Tämän jälkeen siirrytään käyttämään Google Analyticsin mallinvertailutyökalua, jonka avulla viimeisen kosketuspisteen attribuutiomallia verrataan vaimenemisaika- ja sijaintipohjaiseen malliin.

Taulukko 4.

	Viimeinen kosketuspiste	Vaimenemisaika	Sijaintipohjainen	Konversioiden muutos% / vaimenemisaika	Konversioiden muutos% / sijaintipohjainen
Maksettu haku	181 (50.14%)	105.32 (29.18%)	100.87 (27.94%)	-41.81%	-44.27%
Orgaaninen haku	137 (37.95%)	143.97 (39.83%)	144.18 (39.14%)	+4.96%	+5.24%
Display	26 (7.20%)	61.16 (16.94%)	63.21 (17.51%)	+135.23%	+143.12%
Suora liikenne	17 (4.71%)	50.53 (14.00%)	52.34 (14.50%)	+197.23%	+207.88%

Vertailussa huomataan, että nämä vaimenemisaika- ja sijaintipohjainen malli antavat hakumainonnalle selvästi vähemmän arvoa kuin viimeisen kosketuspisteen malli. Samalla molemmat mallit arvottavat display-mainontaa ja suoraa liikennettä huomattavan paljon. Kauppias vetää johtopäätöksen, että display-mainonta todennäköisesti herättää kuluttajien mielenkiinnon, jonka jälkeen he vertailevat vaihtoehtoisia autojälleenmyyjiä, ja palaavat myöhemmin sivustolle hakukoneen kautta varaamaan koeajon.

Mallien vertailun jälkeen display-mainonnan budjettia päätetään kasvattaa, sillä se on selvästi tärkeässä osassa tavoitteen kannalta.

Taulukko 5. Autokauppiaan uusi budjettijako.

Kanava	Kuukausibudjetti
Display	4 000 €
Hakusanamainonta	4 000
Yhteensä	8 000 €

3.4.3 Lopputulos

Tilannetta arvioidaan uudelleen kuukauden kuluttua muutoksista ja verrataan lähtötilanteeseen.

Taulukko 6. Lähtö- ja nykytilanteen vertailu.

	Lähtötilanne	Nykytilanne
Koeajovaraukset/kk	30	40
Myydyt autot/kk	9	12
Liikevaihto/kk	225 000 €	300 000 €
Liikevoitto	20 250 €	27 250 €

Lähtötilannetta ja nykytilannetta verratessa havaitaan, että konversioiden määrä kasvoi, ja koeajovarausten määrän kasvun myötä myytiin kolme autoa enemmän. Myynnin kasvun johdosta myös liikevoitto parani 7 000 €. Myös mikrokonversioiden, eli uutiskirjeiden tilausten ja hinnaston latausten määrä on kasvanut.

Rajatakseen pois sattuman mahdollisuuden konversioiden määrän kasvusta, kauppias päättää markkinointitiimeineen jatkaa mallinnusprosessia samalla budjettiallokaatiolla.

Lisäksi hän päättää toteuttaa asiakkailleen kyselytutkimuksen saadakseen kvantitatiivista tietoa koeajovaraukseen päätymisestä. Tuloksia vertaillaan jälleen kuukauden kuluttua, jolloin vertaillaan eri attribuutiomalleja, tehdään uusi hypoteesi, ja seurataan tuloksia.

Tässä esimerkkitapauksessa uhkana on display-mainonnan budjetin korostaminen hakusanamainonnan kustannuksella. Pienemmällä budjetilla hakusanamainokset eivät välttämättä näy kaikkien kelvollisten hakujen yhteydessä näyttöosuuden laskun takia, jonka vuoksi konversiomäärän kasvu saattaa pysähtyä ja konversiomäärä jopa pienentyä. Optimaalisen budjettijaon löytäminen näiden kahden kanavan välillä onnistuu ainoastaan pitkäjänteisellä ja systemaattisella testaamisella. Lisäksi budjetista voitaisiin irroittaa pieni osa, jolla kokeiltaisiin myös muita kanavia, esimerkiksi Facebook-mainontaa.

Lähteet

Adometry 2013. Measuring the 'Facebook effect' on ad campaign performance. http://services.google.com/fh/files/misc/article_the_facebook_effect.pdf. Luettu 21.11.2015.

Adometry 2012. The evolution of advanced attribution. http://services.google.com/fh/files/misc/infographic_evolution-of-advanced-attribution-infographic.pdf. Luettu 15.11.2015.

Adroll 2015. The step-by-step guide to building your custom attribution model. Opas 1.4.2015. <https://www.adroll.com/resources/guides-and-reports/20150401-custom-attribution-model/view>. Luettu 22.11.2015.

Chaffey, Dave & Smith, PR 2013. Emarketing excellence – Planning and optimizing your digital marketing. 4th edition. Routledge Publishing, New York.

Cutroni, Justin 2013. Measuring the non-profit: from planning to implementation. Blogiteksti 22.4.2013. <http://cutroni.com/blog/2013/04/22/measuring-the-non-profit-from-planning-to-implementation/>. Luettu 5.12.2015.

Cutroni, Justin 2011. Google Analytics Multi-Channel Funnels. Blogiteksti 14.4.2011. <http://cutroni.com/blog/2011/04/14/google-analytics-multi-channel-funnels/>. Luettu 6.12.2015.

Google 2015a. Tietoja Google Tag Managerista. https://support.google.com/tagmanager/answer/6102821?hl=fi&ref_topic=3441530. Luettu 8.11.2015.

Google 2015b. Yleiskatsaus attribuutiomallinnukseen. <https://support.google.com/analytics/answer/1662518?hl=fi>. Luettu 14.11.2015.

Google 2015c. Tietoja oletusattribuutiomalleista. <https://support.google.com/analytics/answer/1665189?hl=fi>. Luettu 14.11.2015

Google 2015e. Tietoja reaaliaikaisesta analytiikasta. <https://support.google.com/analytics/answer/1638635?hl=fi>. Luettu 21.11.2015.

Google 2015f. URL-osoitteiden rakennustyökalu. <https://support.google.com/analytics/answer/1033867?hl=fi>. Luettu 28.11.2015.

Google 2015g. Muokatut kampanjat. https://support.google.com/analytics/answer/1033863?hl=fi&ref_topic=1032998. Luettu 28.11.2015.

Google 2015h. Konversioreittien analysointi. <https://support.google.com/analytics/answer/1191209?hl=fi>. Luettu 6.12.2015

Google 2015i. Tietoja tavoitteista. https://support.google.com/analytics/answer/1012040?hl=fi&ref_topic=6150889. Luettu 9.12.2015.

Google 2015j. Verkkoseurantakoodin määrittäminen.
<https://support.google.com/analytics/answer/1008080?hl=fi>. Luettu 17.1.2016.

Google 2015k. Tietoja monikanavista.
<https://support.google.com/analytics/answer/1191184?hl=fi>. Luettu 19.1.2016.

Google 2015l. Hintatietojen tuonti.
<https://support.google.com/analytics/answer/2803329?hl=fi>. Luettu 9.12.2015.

Google 2015m. Tietoja monikanavien tiedoista.
https://support.google.com/analytics/answer/1319312?hl=fi&ref_topic=1191164. Luettu 9.12.2015.

Jefimoff, Noora 2015. Mitä markkinoinnin pitää tietää tag managementista? Blogiteksti 14.10.2015. <http://www.superanalytics.fi/blogi/mita-markkinoinnin-pitaa-tietaa-tag-managementista/>. Luettu 8.11.2015.

Kaushik, Avinash 2013. Multi-channel attribution modeling: the good, the bad and ugly models. Blogiteksti 12.8.2013. <http://www.kaushik.net/avinash/multi-channel-attribution-modeling-good-bad-ugly-models/>. Luettu 14.11.2015.

Kaushik, Avinash 2012. Dear Avinash: Attribution modeling, org culture, deeper analysis. Blogiteksti 13.8.2012. <http://www.kaushik.net/avinash/multi-channel-attribution-data-culture-analysis-faq/>. Luettu 7.12.2015.

Kaushik, Avinash 2011. Excellent analytics tip #19: Identify website goal (economic) values. Blogiteksti 24.1.2011. <http://www.kaushik.net/avinash/web-analytics-tips-identify-website-goal-values/>. Luettu 29.11.2015.

Kaushik, Avinash 2010. Web Analytics 2.0 – The art of online accountability & science of customer centricity. Wiley Publishing, Indianapolis.

Kaushik, Avinash 2007. Web Analytics – An Hour A Day. Wiley Publishing, Indianapolis.

Mertanen, Petri 2016. Analytiikka ja Google Tag Manager. Koulutus 25.1.2016. GroupM Finland Oy, Helsinki.

Relander, Teemu 2013. Median oma analytiikka. Teoksessa Häivälä, Janne & Pyyhtiä, Tomi (toim.) Digin mitalla – Verkkomarkkinoinnin ja -myynnin mittaamisen käsikirja. Mainostajien liitto, Helsinki.

Salo, Anna 2015. Tokkua digitaaliseen dataan (Mediatoimistot äänessä -blogi). Asiakkuusjohtaja, Dagmar. Blogiteksti 9.3.2015.
<http://blog.kauppalehti.fi/mediatoimistot-aaanessa/tolkkua-digitaaliseen-dataan>. Luettu 3.10.2015.

Tenkanen, Ismo 2013. Ansio konversiosta ostopolun eri vaiheille. Blogiteksti 25.6.2013. <http://www.iab.fi/iablogi/ansio-konversiosta-ostopolun-eri-vaiheille.html>. Luettu 7.11.2015.